

(19) 日本国特許庁 (J P)

(12) 公開特許公報 (A)

(11) 特許出願公開番号

特開平7-209143

(43) 公開日 平成7年(1995)8月11日

(51) Int.Cl.⁶

G 0 1 M 19/00

識別記号

庁内整理番号

F I

技術表示箇所

Z

審査請求 未請求 請求項の数27 O L (全 34 頁)

(21) 出願番号 特願平6-328248

(22) 出願日 平成6年(1994)12月28日

(31) 優先権主張番号 08/176482

(32) 優先日 1993年12月30日

(33) 優先権主張国 米国 (U S)

(71) 出願人 391020193

キャタピラー インコーポレイテッド

CATERPILLAR INCORPORATED

アメリカ合衆国 イリノイ州 61629-

6490 ビオーリア ノースイースト アダムス

ストリート 100

(72) 発明者 シン ハオ ヒューアン

台湾 84202 カオシュン チサン デル

イストリート 17-1

(74) 代理人 弁理士 中村 稔 (外6名)


最終頁に続く

(54) 【発明の名称】 機械故障診断システムと方法

(57) 【要約】

【目的】 設備の効率的のよいメンテナンスを行う、信頼性のある機械故障診断システムを提供する。

【構成】 様々の異なる技術が故障診断システムの信頼性と安定性を向上させるために集積されてきた。故障診断の主な技術は、修正ARTMAP神経回路網アーキテクチャに基づく故障診断回路網(FDN)である。ファジィ論理と物理的なモデルに基づいた仮説検定プロシージャが開示されて、FDNを作動して、FDNによって認識できなかった故障を検知し、複雑な機械状態を解析する。更に、トランスピュータベースの平行式処理技術が用いられて、FDNが4個のT800-25トランスピュータの回路網状で用いられる。



【特許請求の範囲】

【請求項 1】 (a) 知覚信号を収集するデータ獲得モジュールと、(b) 物理的機械、又は工程の故障の検知をオンラインで行い、故障診断を行って、前記故障検知と前記故障診断に関して推奨を行う、前記データ獲得モジュールに接続された診断モジュールと、(c) 前記診断モジュールによって診断できなかった故障状態を識別するように物理的モデルを与える、前記診断モジュールに接続された機械モデル化モジュールと、を備えた故障診断システム。

【請求項 2】 前記データ獲得モジュールは、各々がリアルタイムデータを獲得できる複数のセンサを備えていることを特徴とする請求項 1 に記載の故障診断システム。

【請求項 3】 前記診断モジュールは、パラメトリックモデル化モジュールと、修正 ARTMAP 神経回路網と、ファジィ論理モジュールと、エキスパートシステムを備えていることを特徴とする請求項 1 に記載の故障診断システム。

【請求項 4】 前記機械モデル化モジュールは、ベアリングとギアの物理的モデルを含んでおり、前記修正 ARTMAP 神経回路網の予備訓練のためのデータを与えることを特徴とする請求項 3 に記載の故障診断システム。

【請求項 5】 前記データ獲得モジュールは、自動回帰モデルを用いて、前記知覚振動を前処理する手段を備えていることを特徴とする請求項 1 に記載の故障診断システム。

【請求項 6】 前記診断モジュールは、全体の実行値(RMS)と指数関数的に重み付けされた移動平均法(EWMA)の共分散統計値を用いることによって前記物理的機械又は工程内の異常状態を検知することを含む故障検知を行う検知手段を備えており、制御限界が前記 RMS と前記 EWMA に設定されており、前記知覚状態が、前記制御限界を越える場合には、異常状態が存在することを特徴とする請求項 1 に記載の故障診断システム。

【請求項 7】 前記診断モジュールは、ファジィ論理法を含むモデルベース推論アプローチに基づいた故障識別を行うための識別手段を備えていることを特徴とする請求項 1 に記載の故障診断システム。

【請求項 8】 前記診断モジュールは、故障の確証を遂行し、ユーザーに検知された故障について推奨するエキスパートシステムを備えていることを特徴とする請求項 1 に記載の故障診断システム。

【請求項 9】 前記診断モジュールと前記機械モデル化モジュールは、トランスピュータ回路網上で用いられることを特徴とする請求項 1 に記載の故障診断システム。

【請求項 10】 前記知覚信号は、前記物理的機械又は工程からの振動信号と、圧力信号と、温度振動を備えていることを特徴とする請求項 1 に記載の故障診断システ

ム。

【請求項 11】 前記診断モジュールは、

(a) 第一の層と第二の層を有し、第一の警戒試験を遂行して認識カテゴリーを生成するように構成された、入力パターンを受ける ART モジュールと、

(b) 前記 ART モジュールと目標出力パターンに接続され、前記認識カテゴリーと前記目標出力パターンとの間の写像を遂行し、第二の警戒試験の遂行をトリガする写像フィールドと、

10 を備え、前記第二警戒試験は、前記目標出力パターンと前記認識類別との近さを決定するようになっている故障診断回路網を備えていることを特徴とする請求項 1 に記載の故障診断システム。

【請求項 12】 前記第一の層は、三つのレベルを備えており、上記各レベルは、

フィールド内及びフィールド間の入力の積分を行い、積分された活動化信号を発生する手段と、

前記活動化された振動の正規化を遂行する手段と、

20 を備えていることを特徴とする請求項 11 に記載の故障診断システム。

【請求項 13】 前記 ART モジュールは、二進、或いはアナログ入力パターンを受け入れることのできる ART 2 回路網であることを特徴とする請求項 11 に記載の故障診断システム。

【請求項 14】 前記目標出力パターンは、二進ベクトルであり、該二進ベクトルの各ノードは、特定の機械、あるいは処理状態に対応することを特徴とする請求項 11 に記載の故障診断システム。

【請求項 15】 被検査機械から収集された生振動信号を所定のパラメトリックモデルに適合させて、パラメータを生成するパラメータ手段を備えていることを特徴とする請求項 11 に記載の故障診断システム。

【請求項 16】 前記パラメータ手段に接続され、前記パラメータから有意意味負値を除去する正規化モジュールを備えていることを特徴とする請求項 15 に記載の故障診断システム。

【請求項 17】 前記正規化モジュールは、

(1) 前記パラメータを負部分と正部分とに分割する手段と、

40 (2) 前記パラメータを最大パラメータ値で割ることによって、前記負部分と前記正部分を基準化する手段と、を備えていることを特徴とする請求項 16 に記載の故障診断システム。

【請求項 18】 前記第二層の各ノードは、特定の故障状態に対応することを特徴とする請求項 11 に記載の故障診断システム。

【請求項 19】 前記機械モデル化モジュールは、困難な故障推論機構を形成して、複雑で複数の故障状態を識別することを特徴とする請求項 1 に記載の故障診断システム。

【請求項 20】 (1) 前記物理的機械又は工程から第一組のデータを獲得し、

(2) 自動回帰モデルを用いて前記獲得されたデータを前処理して、自動回帰パラメータを発生させ、

(3) 全体の実行値 (RMS) と指数関数的に重み付けされた移動平均 (EWMA) の共分散統計値を用いることによって、前記自動回帰パラメータ内の異常状態を検知し、異常状態が検知された場合には、

(a) 前記物理的機械又は工程に故障があるかどうかを識別し、(i) 故障診断回路網を用いて故障仮説を決定し、前記故障診断回路網が故障仮説を形成することができない場合には、(i i) ファジィ論理を用いる、モデルベース推論アプローチを用いて故障仮説を決定し、

(b) 一組の規則を備えた知識ベースを有する故障推論エキスパートシステムに前記識別可能故障を供給し、前記故障推論エキスパートシステムは、前記規則に対して、前記識別可能故障をチェックする、段階からなる、物理的機械又は工程を診断する方法。

【請求項 21】 前記機械又は工程が正常方法、故障の起きる可能性をもった方法、危険な方法において作動するというユーザーに示す段階を含むことを特徴とする請求項 20 の段階 (3) に記載の方法。

【請求項 22】 前記故障推論エキスパートシステムは、損失、修復歴、機械使用情報に対して前記識別可能な故障をチェックすることを特徴とする請求項 20 に記載の方法。

【請求項 23】 ユーザーインターフェイスを介して推奨にそって前記識別可能な故障を表示する段階を含んでいることを特徴とする請求項 22 に記載の方法。

【請求項 24】 自動回帰モデルを用いて前記第二組の獲得されたデータを前処理して、前記前処理は、自動回帰パラメータを発生させ、前記自動回帰パラメータを正規化することを特徴とする請求項 20 に記載の故障診断システム。

【請求項 25】 前記物理的機械又は工程から前記段階 3 (a) の前に第二組データを獲得する段階を備えていることを特徴とする請求項 20 に記載の方法。

【請求項 26】 (1) 前記物理的機械又は工程から一組のデータを獲得し、

(2) 物理的機械又は工程が故障しているかどうかを識別し、(i) 故障診断回路網を用いて故障仮説を決定し、前記故障診断回路網が故障仮説を形成できない場合には、(i i) ファジィ論理を用いるモデルベース推論アプローチを用いて、故障仮説を決定する、段階からなる、物理的機械又は工程を診断する方法。

【請求項 27】 一組の規則を備えた知識ベースを有する故障推論エキスパートシステムに前記識別可能な故障を供給する段階を備えていることを特徴とする請求項 26 に記載の方法。

【発明の詳細な説明】

【0001】

【産業上の利用分野】 本発明は、機械故障の診断の分野に関する。より詳細には、機械構成部品の故障の可能性をオンラインによる、リアルタイムで監視するように予測的なメンテナンスを用いるシステムと方法に関する。

【0002】

【実施例】 過去 2、30 年以上にわたって、産業は、生産性と質とを向上させるために様々な段階を経てきた。しかしながら、メンテナンスの分野には、ほとんど注意が払われてこなかった。広い定義におけるメンテナンスは、設備の状態を制御することに関する。各製造会社では、実際にはメンテナンスを行っているが、製造工程におけるサポート的な機能にすぎないと考えられている。つい近年になって、メンテナンスは、製造工程と一体化したものであり、生産性と質を高めることのできるものとして認識されてきた。製造工程におけるロボット、オートメーション、及びより精巧な機械の使用が増えてきて、生産性と質は、機械を操作する人間よりは機械に依るといった方が適切であろう。組立て、荷物の積み卸し、スポット溶接及び点検のような作業において、例えば、ロボットが人間の作業者と取って替わるようになってきた。この精巧な設備を十分に満足のいく状態に保つことは、メンテナンスの必要性を増大させ、メンテナンスを更に複雑なものにする。したがって、長い修復時間と、より高度に訓練された、高額なメンテナンス技術と、技術者が必要とされる。もちろんこれにより、メンテナンス費用がより高くなることになる。

【0003】 自動化の程度が高くなると、メンテナンスの費用も高くなる。多くの製造会社において、メンテナンスの費用は、全作動費用の大きな部分の一つ、例えば労働者に支払う費用よりも高い場合が多いことを示している。このため、近代産業にとって競争力を確保するためには、効率的にメンテナンス費を下げるメンテナンスの戦略方法が重要である。三つの最も一般的なメンテナンスの戦略法は、第一にブレイクダウン、即ち事後保全 (即ち、故障したときに機械を修理する)、第二に予防、即ち一定時間ごとのメンテナンス (即ち、予め定められた時間に基づいて機械を維持する)、第三に予知的な、即ち状態を基本としたメンテナンス (即ち、機械が故障する前に維持する) である。何年にもわたって、殆どの製造会社は、ブレイクダウン、或いは予防メンテナンスのいずれかを用いてきた。このような場合、機械がブレイクダウンするか、或いは機械が故障する危険性を少なくするためにルーチンメンテナンスを行うかのいずれかである。しかしながら、ブレイクダウンメンテナンスは、機械がさほど重要な物ではないときのみ適しており、取替えの費用は安い。生産損失と機械に対して潜在的二次的な停止によるコスト、安全性に対する潜在的な危険性が高い場合には、この戦略法は採用できない。この戦略法を向上させるには、予防メンテナンスを用い

る。

【0004】予防メンテナンスによって機械における損傷の発生が少なくなるが、いくつかの問題を有している。第一に、機械と部品は定期的に故障するとは限らないので、オーバーホールの期間を決定するのは困難である。第二に、オーバーホールの間にできるだけ多くの部品を検査することが賢明であるので、貴重な生産時間が失われる。第三に、適当な状態の部品が不必要に取り替えられることが多い。このように、最も良い戦略方法は、メンテナンスを前もって計画できるように状態、性能及び機械の信頼性を予測する予測的なメンテナンス方法を採用すべきであると考えられる。最近では、生産の質と製造オートメーションの要求が高まってきたので、製造会社は、ますますメンテナンスプログラムの一部として予知的なメンテナンスを採用してきた。これらのことを行うのは、信頼性と生産性及び有効性を増大させ、メンテナンスの費用と、メンテナンスと工場全体の作動の費用を最小にするためである。機械監視と診断は、兆候から故障の発生を予測できるとともに、機械部品或いはシステムにおける故障の原因を特定できる判定—サポート用具と考えられる。機械故障の正確な傾向と識別なしに、メンテナンスと生産スケジュールを予め定めることができなければ、効率的に計画することができず、必要な修復作業を時間内に行うことができない。このように、機械監視及び診断は、効率的な予知メンテナンスプログラムには不可欠なものである。

【0005】機械監視及び診断を用いる最終的な目的は、設備の有効性を増大させ、更に、メンテナンス費用と、予期しない機械のブレークダウン費を減少させることである。利用性を最大限にするために、平均故障間隔を最大にすることによって信頼性を高め、同時に、平均修復時間を最小にすることによって保全性を高める。一定の監視及び診断の結果、予期しなかった機械の損傷の頻度は、かなり減少し、機械の故障が即座に正確に指摘される。この結果、信頼性と保全性が増大する。機械監視及び診断は、機械の状態を判定するために機械作動中に発生した音を聞くだけで行ったり、或いは機械部品の質を眼で検査するだけで行うことができる。しかしながら、このような状態において、機械の故障を識別することは、殆どの場合、作業員、或いはエンジニアの経験に依る。その上、多くの機械故障は、特に作動中の間（例えば、ベアリングとギアボックスの磨耗とひび割れ）、視覚と聴覚による観察のみでは正確に判定できない。このように、振動解析、油解析、音響的なエミッション、赤外線及び超音波のような精巧な信号処理技術が開発されて、メンテナンス技術及びエンジニアの検知を助けて、機械故障を診断する。

【0006】機械監視及び診断に使用されるべき信号処理技術の種類は、処理するべき故障の種類とともに、監視されるべき機械のパラメータの種類に依る。振動、

音、温度、力、圧力、電流、潤滑油等の監視可能な、複数の機械パラメータがある。何が最も効率が良いかを判定するために多くの研究が導かれてきた。しかし、いかなるパラメータも機械故障の全範囲を示すことはできない。複数の機械パラメータを組合せて用いることによって、機械の状態をより正確に、より信頼性をもって示唆することができるのは公知である。このような場合、保全員は、所定の種類の故障を検知できるとともに、多くの異なる信号処理技術に熟知していなければならない。更に、大量のデータが収集され、解析され、理解されなければならない。このことは、保全員が正しい診断を行うのには、長い時間と知識が要求されることを意味する。過去20年にわたって、殆どの機械監視及び診断システムは信号処理技術を用いてオフラインで実施してきた。これらシステムの成功は、一つの信号処理技術によるものではなく、複合信号処理に対応する多量の冗長度のおかげである。しかしながら、これらの信号処理技術は、使用する際には非常に複雑であり、更に、正確な診断を行うためには、高度な訓練と経験を積んだ解析者によってなされなければならない。正確な故障診断は、特に、発生サイクル時間を減少させることについて重要である。正確で早い故障診断の結果、設備のメンテナンスの可能性と有効性がかなり改良され、これにより生産サイクル時間を短くすることになる。エキスパートシステム、ファジィ集合、パターン認識、人工神経回路網のような多くの新しい技術が提案されて、この目的を達成するのに役立ってきているが、各方法は、様々な異なった能力を有し、様々な制限を受けるので依然として普遍的な方法が存在しない。

【0007】下記は、信号処理（例えば、信号解析とパラメトリックモデリング）、人工知能、人工神経回路網及び知覚融合のような機械監視及び診断の最も関連する四つの技術を説明する。何年にもわたって、機械監視及び診断システムは、プロセスからセンサデータを収集し、信号処理技術によってオフラインデータを解析することによってなされてきた。最も広く使用されてきた信号処理技術の一つには、振動解析がある。これは、他のパラメータでは振動のような広い範囲の機械故障を明らかにできないからである。振動解析は、計測された振動信号からの情報抽出を処理するものである。振動特性は、機械の状態が変化するにつれて変わることがわかる。回転要素に磨耗や損傷を生じたり、不均衡や共振を生じると、過度の振動が発生する。一般的に、振動データは、二つの異なるドメイン、即ち時間と周波数により分析できる（J. Tranter, "The Fundamentals of , and The Application of Computer to, Condition Monitoring and Predictive Maintenance," Proceedings of the 1st International Machinery Monitoring and Diagnostics Conference and Exhibit, Las Vegas, NV, September 1989, pp. 394-401 and C. J. Li and J. M. Wu, "On-

Lien Detection of Localized Defects in Bearings by Pattern Recognition Analysis, "Journal of Engineering of Industry Vol.111, November 1989, pp. 331-336 を参照)。時間ドメイン解析は、観察されたインパルス振動量に対応するインデックスを設定することを含んでいる。この技術は、全体のレベル(RMS)計測と、ピークレベル検知と、波高率、ショックパルス、スパイクエネルギー、とがり解析、時間波形、軌道関数を含んでいる。周波数ドメイン解析は、振動波形を変換し、異なる周波数でインパルスの列を示す。この技術は、スペクトル解析、淹プロット、ケプストラム解析、微分スペクトル、微分スペクトルのRMS、エンベロープ解析、高周波数共振解析(HFRF)及び整合フィルタを含んでいる。

【0008】最もパワフルな振動解析技術の一つは、スペクトル解析であり、高速フーリエ変換(FFT)を実施することによって振動信号からスペクトル、或いはパワースペクトル密度(PSD)を推定することができる。FFTベースの技術がよく使われるのは、計算速度が速いからである。更に、機械振動スペクトルは、機械部品の状態についての重要な情報を生み出す。機械内の各回転部品が識別可能な周波数を発生させるからである。これにより、与えられた周波数の範囲における変化は、特定の部品の故障に直接的に関与できる。しかしながら、FFTベース技術には、低周波解像度、データの暗示的なウィンドー、データの残りが大きくないといったいくつかの問題点がある。スペクトル解析の他に、パラメトリックモデリング技術が、振動スペクトルを推定するために使用されてきた。これは、上述したFFTアプローチの本質的な制限を解消することを意図して使用される。パラメトリックモデリング技術を用いることには、二つの主な利点がある。第一に、実信号からのノイズを抑圧することによって、FFTを越える周波数共振を改良することであり、第二に、信号を包括的に表すようにいくつかのパラメータを用いることによるデータの編集である。

【0009】多くのパラメトリックモデリング技術、例えば自動回帰(AR)法、自動回帰及び移動平均(ARMA)法、プロニー法、最小分散法、及び共分散法のような方法が振動スペクトルを評価するために報告されてきた。これらの技術を詳細に見直してみると、S.M. Kay, S.L. Marple, "Spectrum Analysis -- A Modern Perspective," Proceedings of the IEEE, Vol. 69, No. 11, November 1981, pp 1380-1419とs. Braun, MMechanical Signature Analysis: Theory and Application, Academic Press, London 1986 でみることできる。上述したパラメータ方法は、故障検知の分野に適用されてきた(Matsushima et al., "In-Process Detection of Tool Breakage by Monitoring the Spindle Current of a Machine Tool," Proceedings of ASME Winter Annual Meet-

ing, Phoenix AZ, 1982, pp. 145-154; M. Sidahmed, "Contribution of Parametric Signal Processing Techniques to Machinery Condition Monitoring," Proceedings of the 1st International Machinery Monitoring and Diagnostics Conference and Exhibit, Las Vegas, NV, September 1989, pp. 190-195, S.Y. Liang and D.A. Dornfeld; "Tool Wear Detection Using time Series Analysis of Acoustic Emission," Journal of Engineering for Industry, Vol. 111, August 1989, pp. 199-205; Wu et al., "Signature Analysis for Mechanical System via Dynamic Data System(DDS) Monitoring Technique," Journal of Mechanical Design, Vol. 102, April 1980, pp. 217-221を参照)。

【0010】パラメトリックモデリングの欠点は、モデルの最適順序を見つけ出すことが容易ではないことである。モデル順序の選択における一般的なガイドラインは、誤差の二乗の総和の最小化に基づく。H. Akaike, "Power Spectrum Estimation through Autoregression Model Fitting," Ann. Inst. Stat. Math., Vol. 21, 1969, pp. 407-419 と、"A New Look at the Statistical Model Identification," IEEE Trans. Autom. Control, Vol. AC-19, December 1974, pp. 716-723, では、最終予測誤差(FPE)とアカイク情報基準(AIC)の二つの基準が提唱されており、順序選択のための目的関数として用いることができる。C.C. Linの最近の研究である"Classification of Autoregressive Spectral Estimated Signal Patterns Using an Adaptive Resonance Theory(ART)," Master's Thesis, Department of Industrial Engineering, The University of Iowa, Iowa City, August 1992 において、最高レベルのFPEとAICレベルで最適な順序が選択される。上述の両方のパラメータモデルは、機械故障を早期に検出する際にはうまく利用されてきたが、故障の原因を識別することができない。通常は、スペクトルの視覚的な検査によって、故障の原因を識別する解析者が、この故障認識作業を行う。正確な診断を行うためには経験と知識が要求されるので、これは容易な作業ではない。

【0011】振動解析とパラメトリックモデリング技術は、機械監視及び診断に有効であると証明されてきたが、それらは、知能一集中技術である。換言すると、機械故障の原因を正確に識別するために、高度な訓練を受け、経験の豊富なエンジニアによってなされなければならない。この問題を解決するために人工知能アプローチが提案されてきた。過去2、3年にわたって、故障診断にたいして人工知能を適用することは大いに注目を受けてきた。二つの最も一般的な人工知能のアプローチはエキスパートシステムとモデルベース推論である。人工知能の分野において最も大きな成功の一つは、エキスパートシステムである。エキスパートシステムは、プログラムされて、特定のドメイン問題を解決する際に、セキス

パート知識を表す、コンピュータシステムである。典型的なエキスパートシステムは、次の構成要素からなる。知識ベース（問題についての知識を含む、例えば規則と要素）

推論エンジン（規則と要素を組み合わせて、結論に達する方法）

説明構成要素（何故、如何にこの結論に達したかを説明する）

ユーザーインターフェイス（知識とデータ獲得を含む）

一般的に、知識は、兆候（IF）—原因（THEN）規則の形状で表される。この規則は、エキスパートにより作られた問題—解決ヒューリスティックに基づく。推論エンジンは、知識ベースの使用を制御する。この制御戦略法は、要素、即ち兆候から開始して結論（前向き連鎖）に達するか、或いはその要素を通して可能な結果と検索から結論を確定する（後ろ向き連鎖）。

【0012】過去何年もの間、多くのエキスパートシステムは、機械診断を開発してきた。故障診断エキスパートシステムの詳細なサーベイは、S. G. Tzafestas, "System Fault Diagnosis Using the Knowledge-Based Methodology," *Fault Diagnostics in Dynamic Systems: Theory and Applications*, edited by R. Patton, P. Frank, and R. Clark, Prentice-Hall, New York 1989) に見ることができる。エキスパートシステムは、容易に使用でき、エキスパート知識を提供して特定のドメイン問題を解決するが、このアプローチ (J. M. N. Davit and J. P. Krivine, "Three Artificial Intelligence Issues in Fault Diagnosis: Declarative Programming, Expert Systems, and Model-Based Reasoning," *Proceedings of the Second European Workshop on Fault Diagnostic* s, Reliability and Related Knowledge Based Approaches, UMIST, Manchester, April 6-8, 1987, pp. 19-196) を用いるのには、例えば、問題を書式化する困難性、知識を獲得する困難性、システムを妥当にする困難性といった多くの問題がある。更に、機械監視及び診断のエキスパートシステムを形成するには多くの欠点がある。主な欠点の一つは、実行時間が長いことである。複雑な関係と膨大な知識ベースがこの推論プロセス内に含まれているときに、このことは特に著しい。エキスパートシステムは、結論に達するために推論の複雑な連鎖を介して作業をしなければならないので、処理時間がさらに長くなる。このように、オンライン機械監視及び診断を実施するのに要求される反応時間が短いために、この分野におけるエキスパートシステムを適用させることを困難にし、実行不可能なものにする。

【0013】エキスパートシステムに対する他のアプローチとして、モデルベース推論が診断推論問題を解決するのに提案されてきた。モデルベース推論の最も見込みのある技術の一つは、“構造と作動からの推論” (R. Davis, "Diagnostic Reasoning Based on Structure and B

ehavior," *Artificial Intelligence*, Vol. 24, 1984, p. p. 347-410) である。この技術は、システム作動の観察とともに、システムの表示で始まる。この観察が、システムが作動しようとする方向と衝突する場合には、システムの故障の発生がわかる。誤作動という兆候が与えられると、はずれた予測から、この予測に貢献した各構成要素に従属連鎖が引き戻されりうことによって、構造モデル用いて、考えられる故障の候補が識別される。診断の問題に対するモデルベースの推論の公知の出願の多くは、デジタル電子分野であった。デジタル回路の構造はかなり明確に表すことができ、この回路の意図された作動がこの回路構造によってかなり強く暗示されているからである。モデルベースのシステムに対する知識の獲得は、エキスパートシステムのアプローチに較べて容易である。更に、モデルベースシステムは、より強く、保全可能である。モデルサイズが指数関数的に成長することなく、複数の故障を診断することができる。しかしながら、リアルタイムの問題が依然としてある。システムは、故障の可能性全てを見つけ出し、可能性に従ってひとつずつ分類しなければならず、推論時間がより長くなるからである。

【0014】機械、即ち部品の故障の識別は、実際にはパターン認識の問題である。過去において、線形判別関数とファジィ集合のような多くのパターン認識技術がこの種の問題を解決するために採用されてきた。通常、これらの技術は機械、即ち部品の状態を二つの状態、即ち正常か異常に分類する。近年、人工神経回路網が、機械監視及び診断の分野において成功をおさめてきた。例をみると、Deitz et al., "Jet and Rocket Engine Fault Diagnosis in Real Time," *Journal of Neural Network Computing*, 1989, pp. 5-18, Marko et al., "Automotive Control System Diagnostics Using Neural Nets for Rapid Pattern Classification of Large Data Sets," *Processing of International Joint Conference on Neural Networks (IJCNN)*, Vol. 11, 1989, pp. 13-15, Sunil et al., "Machining Condition Monitoring for Automation Using Neural Networks," *Monitoring and Control for Manufacturing Processes: Presented at the Winter Annual Meeting of the ASME*, Dallas, TX, November 25-30, 1990, pp. 85-100, Hoskins et al., "Incipient Fault Proceedings of the International Joint Conference on Neural Networks (IJCNN)", Vol. 1, 1990, pp. 81-86, T. I. Liu and N. J. Ko, "On-Line Recognition of Drill Wear via Artificial Neural Networks," *Monitoring and Control for Manufacturing Processes: Presented at the Winter Annual Meeting of the ASME*, Dallas, TX, November 25-30, 1990, pp. 101-110, Y. Guo and K. J. Dooley, "The Application of Neural Networks to a Diagnostic Problem in Quality Control," *Monitoring and Control for Ma*

ufacturing Processes: Presented at the Winter Annual Meeting of the ASME, Dallas, TX, November 25-30, 1990, pp. 111-119, T. I. Liu and J. M. Mengel, "Detection of Ball Bearing Conditions by an A. I. Approach," Proceedings of the Winter annual Meeting of the ASME, Atlanta, GA, December 1-6, 1991, pp. 13-21, and G. M. Knapp and H. -P. Wang, "Machine Fault Classification: A Neural Network Approach," International Journal of Production Research, Vol. 30, No. 4, 1992, pp. 811-823 がある。

【0015】人工神経回路網に伴う最も大きな問題点の一つは、神経回路網は、決してこれら自身を説明しないということである。神経回路網の適用に対して、このいわゆる“ブラックボックス”アプローチを除去するために、神経回路網ワークシステムに表現能力を形成することが必要である。明白なアプローチは、エキスパートシステムと神経回路網をハイブリッドシステムとなるように組み合わせることである。エキスパートシステムと神経回路網の組合せの例を、"M. Cauldill, "Using Neural Nets: Hybrid Expert Networks," AI Expert, November 1990, pp. 49-54, D. V. Hillman, "Integration Neural Nets and Expert Systems," AI Expert, June 1990, pp. 54-59, Kraft et al., "Hybrid Neural Net and Rule Based System for Biler Monitoring and Diagnosis," Proceedings of the 53rd Annual Meeting of the American Power Conference, Chicago, IL, April 29-May 1, 1991, pp. 952-957 ;and Rabelo et al., "Synergy of Artificial Neural Networks and Knowledge-Based Expert Systems for Intelligent fMS Scheduling," Proceedings of the International Joint Conference on Neural Networks(IJCNN), Vol. 1, 1990, pp. 359-366にみることができる。

【0016】複合センサの集積として表されることの多いセンサ融合は、様々なセンサから得られた情報を集積する一処理である。これは、判定を行う、特に個々のセンサからの情報が一般的に雑音があり、不正確で、不十分なところで像、即ち信号処理を採用する際に、人間と同じような性能を達成する（例えば、人間の知覚から効率的にうなを組み合わせる能力）ことを期待して利用される。センサ融合を用いた四つのキーとなる利点がある。第一に、同特性に関して一グループのセンサ（或いは時間に対する単一センサ）から獲得した冗長情報の融合は、精度が高まるとともに、センサ誤差、即ち故障の場合における信頼性を高めることができる。第二に、要求された情報がこのセンサが単一で作用することによって得られなかった場合に、補足的な情報が、複数のセンサを使用することによって生じ、異なる特性を計測することができる。第三に、複数のセンサは、特に、平行性が積分処理に含まれているときに、単一のセンサによって得られる速度と比較して、より適時に情報を提供で

きることである。第四に、マルチセンサは、個々のセンサから獲得した同等の情報と比較したときに、低コストで要求された情報を提供することができる。(J. M. Fildes, "Sensor Fusion for Manufacturing," Sensors, January 1992, pp. 11-15, and R. C. Luo and M. G. Kay, "Multisensor Integration and Fusion: Issues and Approaches," Sensor Fusion: Issues and Approaches," Sensor Fusion: Proceedings of the SPIE, Vol. 931, 1988, pp. 42-49 を参照)センサ融合の目的は、個々のセンサからの情報の総和よりも高いレベルの情報を与える代替的なパターンとなるように個々の情報を組み合わせることである。個々のセンサからの情報は生データか、或いは処理されたデータとすることができる。処理されたデータは、前処理された手順によって発生し、一般的にパターン認識、ノイズフィルタリング、或いは、データ減少を遂行する。パラメータ（自動回帰モデルのパラメータのような）を概算、或いは所定の命題を或いはある仮説に適合した判定を支持する証拠のいずれかの形状とすることができる。

【0017】信頼性があり一定した情報を提供するために異なるタイプのセンサを集積する方法を判定することは、センサ融合において最もチャレンジ的な作業である。しかしなら、多くの方法が、この作業を達成するのに適用できる。これらの方法は、統計学的な推論の低レベルな確率分布から、論理学的推論の高レベルな生産ルールにまで及んでいる。センサ融合の6個の一般的な方法を見直すために、R. C. Luo and M. G. Kay, "Multisensor Integration and Fusion: Issues and Approaches," "Sensor Fusion: Proceedings of the SPIE, Vol 931, 1988, pp. 42-49, を参照する。更に、G. Chryssosouris and M. Domrosese, "Sensor Integration for Tool Wear Estimation in Machining," Sensors and Controls for Manufacturing: presented at the Winter Annual Meeting of the ASME, Chicago, IL, November 27-December 2, 1988, pp. 115-123, and "An Experimental Study of Strategies for Integrating Sensor Information in Machining," Annals of the CIRP, Vol. 38, No. 1, 1989, pp. 425-428 では、センサ融合の異なる4つの方法の見直しと比較を行っており、神経回路網アプローチは、特にセンサベースの情報と実際のパラメータとの間の関係が非線形であるときにパラメータ推定を行うための関係を学ぶときに、より効果的であるという結論に達する。即ち神経回路網アプローチは、センサベースの情報における判定的誤差に、判定は、他の3つのアプローチよりも反応しないということである。

【0018】

【発明が解決しようとする課題】機械監視及び診断の分野におけるいくつかの一般的なアプローチは上述した通りである。各アプローチは、その強度性と弱点を有する。相当の研究が、各個々のアプローチの開発と適用の

ために行われてきた。しかしなら、殆どの研究は、これら異なるアプローチを智能システムに組み入れられてこなかった。

【0019】

【課題を解決するための手段】本発明は、機械部品の故障可能性をオンラインによるリアルタイムで監視することを提供する。機械診断システムは、幾つかの異なる技術を集積して、物理的機械又は工程において故障の可能性のある状態を検知し、更に保全員にこれを警告するものである。この機械診断システムは、神経回路網と、エキスパートシステムと、物理的モデルと、ファジィ理論との集積を含む。故障診断に使用された主な技術は、修正したARTMAP神経回路網アーキテクチャに基づいた故障診断回路網（FDN）である。この修正されたARTMAP回路網は、段階的に学習する独特な特性を有する、効率の良い、頑強なパラダイムである。後方伝播のような他の一般的な神経回路網とは異なり、新しいパターンが発見されるたびに新旧全てのパターンで訓練する必要がない。修正ARTMAP回路網は、入力パターンを受け入れるARTモジュールを含んでいる。ART2神経回路網は、基準ARTモジュールとして用いられる。ARTモジュールは、目標出力パターンを入力として受け入れる写像フィールドに接続される。写像フィールドは、ARTモジュールによって供給された認識パターンと、目標出力パターンとの間の写像を遂行する。写像フィールドは、また認識カテゴリーと目標出力パターンとの間の近さを決定する警戒試験をトリガする。修正ARTMAP回路網の訓練の間、入力パターンと所望の出力パターンが修正ASRTMAP回路網に与えられる。回路網試験段階の間、入力パターンのみが与えられる。

【0020】更に、本発明は、物理的モデルとファジィ理論を用いて、仮説検定手順を組み入れ、さらに優れた診断能力を形成する。仮説検定手順はFDNを補足する。FDNは、複雑な知識も、未知の故障状態の全てを解析し、かつ指摘するのに必要な推論能力も含んでいないので、物理的モデルとファジィ理論は、診断システムの診断能力を非常に高める。物理的モデルとファジィ理論は、1) 理論的な予測に基づいて、共通の故障のための診断回路網の予備段階の訓練を提供する手段と、2) 不定期に起こる、複雑な故障状態のために、成功なオフライン診断能力を提供する手段として、二つの方法で用いられる。好ましい実施例において、機械診断システムは、故障推論エキスパートシステム（FRES）を採用する。修正ARTMAP回路網によって、確信的に検出することのできなかった異常状態の可能性のある、いかなるデータサンプルも解析のためにFRESに送られる。同様に、修正ARTMAPが二つ以上の種類の故障（例えば、不整列と汚損）を推測する場合には、データサンプルがFRESに送られる。FRESは、知識ベー

ス、損失、または修復歴、機械の使用情報における記憶に対して、識別可能な故障をチェックし、故障が起こりうると判定する。

【0021】オンラインシステム内での敏速な処理を要求することが、並列式処理を採用する動機となる。トランスピュータベースの並列式処理技術を開示する。FDNを四個のT800-25トランスピュータの回路網上で実現する。本発明の上述と更に他の利点は、添付の図面を参照することによってより良く理解することができるであろう。

【0022】

【実施例】

1. 概要

本発明は、機械部品の故障の可能性に対するオンラインのリアルタイムでの監視を提供する。機械診断システムは、神経回路網、エキスパートシステム、物理的モデル及びファジィ理論を用いて開示されており、故障状態の可能性を検知してメンテナンス保全員に警告する。図4は、集積された機械監視診断システム400の高レベルブロック線図である。診断システム400は、データ獲得モジュール410、診断技術モジュール420、機械モデル化モジュール430、データベースモジュール440、ユーザーインタフェイス450及びシステム制御モジュール460の六つのモジュールを備えている。データ獲得モジュール410は、機械からの振動、圧力及び温度のようなセンサ信号を収集する。これは、複数のセンサ（例えば、促進メータ、聴覚エミッションセンサ、圧力トランデューサ、熱結合等）と、リアルタイムデータ収集のためのデータ獲得ハードウェアとソフトウェアプログラムからなる。診断技術モジュール420は、オンライン故障検知と、故障診断を行っており、パラメトリックモデリング、神経回路網、ファジィ理論及びエキスパートシステムのような複数の異なる技術を用いることによってエキスパートな推奨を与える。ベアリングとギアのための物理的なモジュールを含む、機械モデル化モジュール430は、共通したベアリングとギアの故障に対して神経回路網の予備訓練用のデータを提供する。更に、機械モデル化モジュール430は、複雑な故障推論機構を形成し、複雑な、即ち複数の故障状態を識別する。

【0023】データベースモジュール440は、損失或いは修復歴、神経回路網訓練ログ、作動状態及び機械の使用法のような、重要なシステムの情報を含んでいる。ユーザーインタフェイスモデル450は、ユーザーにとって親しみやすい環境を提供し、システム間で相互に作用しあう。この機能は、機械の状態と情報を表示すること、ユーザーによる入力を受け入れること等を含んでいる。システム制御モジュール460はモジュール間の活動を制御し、調整する。モジュール460は、またデータベース処理活動を制御する。診断システム400

は、自動回帰 (AR) モデルを使用して、振動と音のよう
な知覚入力を前処理する。データが処理されると、図
8に示すように、故障診断は、異なる三つのレベルで行
うことができる。故障検知レベル 710で、全体の実行
値の (RMS) の平均化と、指数関数的に重み付けされ
た移動平均 (EWMA) 法の共分散統計値に基づいたイン
デックスを用いて、オンラインによる機械以上状態を
検知する。制御制限は各 RMS 或いは EWMA のインデ
ックスごとに設定される。異常状態は、新しい知覚デー
タの RMS 或いは EWMA 計測が各制御制限値を越える
時に、必ず検知される。次いで、知覚データは、次の解
析のために故障識別レベル 720 に送られる。EWMA
は、以下に詳細に述べられており、また Spoerre, J. K.,
"Machine Performance Monitoring and Fault Classif
ication Using an Exponentially Moving Average Sch
eme," Masters Thesis, The University of Iowa, May
1993 に述べられている。RMS は公知であり、簡潔に
するために本明細書では詳細に述べない。

【0024】故障識別レベル 720 で、故障診断回路網
(EDN) は、知覚データから機械故障を区別するのに
用いられる。付加的な知覚データは、診断の精度を高め
るために得ることができる。故障診断回路網は、いかな
る故障仮説をも生み出すことができず、モデルベースの
推論アプローチは、故障の可能性を見いだすように機械
モデルを介して論証するために採用される。機械モデル
の故障推論がファジィ論理 (FL) 法を使用することによ
って達成される。この推論処理の出力は、識別可能な
故障と、故障の可能性である。検証及び推奨のレベル 7
30 で、全ての識別可能な故障が、故障推論エキスパー
トシステム (FRES) を介して確認される。FRES
は、知識ベース、損傷或いは修復の経歴及び機械使用法
の情報におけるルールに対して故障をチェックし、最も
あり得る故障を判定する。最後に、識別された機械故障
を補正する推奨がユーザーに対して FRES によってな
される。次いでユーザーは、システムの推奨に従って機
械を検査することができ、データベース 440 内の診断
情報を記憶することができる。この積分システムに対す
る故障診断仮説は図 16 と図 17 B に示されたフローチ
ャートで詳細に表す。図 16 と 17 はセクション 4、5
で詳細に記載する。

【0025】図 1 を参照すると、本発明が、予測適合共
振論 (ART) 或いは、ARTMAP といわれる神経回
路網アーキテクチャ 100 を使用しており、任意的な
順序になったベクトルを予知的な成功に基づいて認識カ
テコリーに分類するように自律的に学習する。Carpente
r, G. A., Grossberg, S., and Reynolds, J., "ARTMAP:
Supervised Real-Time Learning and Classification o
f Nonstationary Databy a Self-Organizing Neural Ne
twork," Neural Networks, Vol 4, 1991, pp. 569-588
を参照する。この監視学習システム 100 は、一対の A

RT モジュール (ART。110 と ART。120) から
構成されており、任意的に連続した入力パターンに応
答して自己編成安定型認識カテゴリーとすることができ
る。ART モジュールの二つのクラスは、カーペンタと
グロスバーク (Carpenter, B. A. and Grossberg, s. "A M
assively Parallel ARchitecture for a Self-Organiz
ign Neural Pattern Recognition Macvhien, "Computer
Vision, Graphics, and Image Processing, Vol 37, 1
987, pp. 54-115 and Carpenter G. A. and Grossberg,
S., "Art 2: Self Organization of Stable Category R
ecognitionCodes for Analog Input Patterns," Applied
Optics, Vol 26, No. 23, 1987, p. p. 4919-1930) によ
って開発されてきた。ART 1 では、任意的に連続した
二進入力パターンを処理することができるが、ART 2
は、二進、或いはアナログ入力パターンのいずれかを
処理することができる。これらの ART モジュールは、
写像フィールド 130 とリアルタイムにおける自律シス
テム作動を行う内部コントローラによって連結されてい
る。写像フィールド 130 は、ART。認識カテゴリー
から ART。認識カテゴリーへの連想写像を認識し、A
RT。警戒パラメータ 140 (ρ') の追跡にあうよう
に制御する。警戒パラメータ 140 は、ART。認識カ
テゴリーと ART。認識カテゴリーとの間の近さを判定
する。

【0026】神経回路網アーキテクチャと訓練法は、
ARTMAP アーキテクチャの修正であることを表
す。図 2 は、修正 ARTMAP 回路網 200 を表す。修
正 ARTMAP は、段階的に学習する独特な特性を有す
る段階的かつ強靱なパラダイムである。後方伝播のよ
うな他の一般的な神経回路網とは異なり、修正 ARTM
AP 回路網 200 は、新しいパターンが発見されるごと
に、新旧全てのパターンで訓練される必要はない。修正
ARTMAP 回路網 200 は、入力パターン 210 (入
力ベクトル 210 として示されている) を受け入れる A
RT モジュール 225 含んでいる。ART 2 神経回路網
は、基準 ART モジュール 225 として使用される。A
RT モジュール 225 は、目標出力パターン 220 (目
標出力ベクトル 220 として示されてもいる) として受
け入れる写像フィールド 230 に接続されている。写像
フィールド 230 は、ART モジュール 225 によって
供給された認識カテゴリーと目標出力パターン 220 と
の間の写像を行う。写像フィールド 230 は、また認識
カテゴリーとターゲット出力パターン 220 との間の近
さを判定する、警戒テスト 240 をトリガする。

【0027】修正 ARTMAP 回路網 200 のトレー
ニングの間に、入力パターン 210 と所望の出力パターン
220 との双方が回路網 200 に与えられる。好ましい
実施例において、入力パターン 210 は、200 のデー
タポイントからなる。所望の出力パターン 220 は、各
ベクトルのノードが特定の機械状態に対応した状態で、

二進ベクトルである。回路網テストの段階の間、入力パターン 210 のみが修正 ARTMAP 回路網 200 に与えられる。

2. 指数関数的に重み付けされた移動平均 (Exponentially Weighed Moving Average)

A. 論理的な背景とモデリング

(a) パラメトリックモデリング方法

$$\hat{y}_t = a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} \quad (1)$$

【0029】p は、モデル内の自動回帰パラメータの数である。
10 ※自動回帰プロセスは、異なる形状の式で表される。

(b) 自動回帰プロセス

$$X(n) = \sum_{i=1}^p \phi_i X(n-i) + e(n) \quad (2)$$

【0031】ここで x (n) はリアルランダムシーケンスであり、 Θ_i 、 $i=1, \dots, p$ はパラメータであり、e (n) は独立したシーケンスであり、一定の分散値を有する、識別的に分布されたゼロ平均のガウスラン★

*パラメトリックモデリング法は、新しいデータ、或いは自動相関作用推定において、情報の統計的数値のプリアリ (priori) モデルに対応する、一組のパラメータを算出するように作動する。この概念は、図 19 に示す。ここで Y_t は、式 (1) の通りである。

【0028】

【数 1】

【0030】

※ 【数 2】

★ダム変数である。即ち、次の通り式 (3)、(4)、(5) で表される。

【0032】

【数 3】

$$E\{e(n)\} = 0 \quad (3)$$

$$E\{e(n)e(j)\} = \begin{cases} \sigma^2 N, & \text{for } n=j \\ 0 & \text{for } n \neq j \end{cases} \quad (4)$$

$$f_{e(n)}(l) = \frac{1}{\sqrt{2\pi}\sigma_N} \exp \left\{ \frac{-l^2}{2\sigma_N^2} \right\} \quad (5)$$

【0033】シーケンス e (n) は、白色ガウスノイズといわれる、このように、入力、或いは力関数が白色ガウスノイズ (ジャンジ、S. 他の I E E スペクトルページ 42 の (Embedding spectral analysis in equipment) を参照) のときに、自動回帰プロセスは、線形微分式モデルである。このように、正常な状態における機械操作にとって、機械の振動状態は AR プロセスによって表され、e (n) の値は白色ガウスノイズである。

(C) モデル有効性

モデルが適当である場合には、振動信号はこのモデルによって広い範囲に定義され、一定時間内の各点ごとに実際信号からの予知信号の偏差、即ち残余は、白色ガウスノイズとして分布し、このために任意的に平均値ゼロのまわりに分布される。推定統計学的な要素が白色ノイズであり、振動信号の動向が適切にモデル化される場合には、時間に対する残余のプロットが、識別可能なパターンを備えない長方形の分散プロットを表し、分散は、一定であると考えられる。この予測的な不規則な残余の分布は、図 18 に示すように、正常な機械状態を表す一組のデータの時間に対する残余のプロットに現れる。

【0034】全体の異常は、残余のヒストグラムをプロットすることによって求めることができる。誤差が正常に分布されていると考えられるので、ヒストグラムは、正常分布にかなり似通っているべきである。正常性に対する最終的なチェックが、残余の正常なスコアを計算することによって導かれた。t_{th} 正常スコアは、標準的な正常分布の $(t-3/8) / (n+1/4)$ パーセントポイントであると定義される。正常分布データで、t 番目のデータ値 (残余) のプロット、対する対応する正常スコアはほぼ直線状となる。この現象は、正常データ集合 (図 3—図 4 を参照) の正常プロット内で生じる。同様に、他の 7 つデータ集合のそれぞれは標準残余、対正常スコアのプロットにおいてほぼ直線で示される。

(d) AR パラメータの選定

AR パラメータの判定は、ユールウオーカー (Yule-walker) 法、バーク (Burg) 法、共分散、変形した共分散法などのようないくつかの技術のうちのひとつによって達成される (Marple, S., Digital Spectral Analysis with Applications, Prentice-Hall, Inc., 1987, pp. 224-231, 251 を参照)。好ましい実施例に

において、修正した共分散法が用いられるのは、他の方法を用いることによって生じる問題、例えば周波数共振、スペクトル線スプリット、及び周波数推定のバイアス (Jangi, S., et al., "Embedding spectral analysis in equipment," IEEE Spectrum, February 1991, p. 42 を参照) を除去するからである。

【0035】(e) AR順序の選択

ARモデル順序の選択に用いられた基準は、最終予測誤差(FPE)、アカイケ情報基準(AIC)、及び標準自動回帰伝達関数(CAT)である。FPEは、ワンス

ここでNは、データサンプルの数であり、pは、順序、 $\hat{\rho}_p$ は、推定された白色ノイズ分散の値である。

【0038】AICは、情報理論関数を最小にすることによってモデル順序を決定する。処理がガウス統計を有すると推定した場合、AR処理のAICは次のような式になる。

【0039】

【数5】

$$AIC[p] = N \ln \hat{\rho}_p + 2p \quad (7)$$

【0040】最終的な標準、CATは、実際の予測誤差フィルタの平均二乗誤差と推定されたフィルタとの間の差の概算を最小にするものとして順序pを選択する。この差は、次の式から計算される。

【0041】

【数6】

$$CAT[p] = \left(\frac{1}{N} \sum_{j=1}^p \frac{1}{\hat{\rho}_j} \right) - \frac{1}{\hat{\rho}_p} \quad (8)$$

【0042】PはCAT[p]を最小にするように選択される。

$$x_p[n] = \begin{pmatrix} x[n] \\ x[n-1] \\ \vdots \\ x[n-p] \end{pmatrix}, \quad a_p^{fb} = \begin{pmatrix} 1 \\ a_p[1] \\ \vdots \\ a_p[p] \end{pmatrix} \quad (11)$$

$$\rho^{fb} = \frac{1}{2} \left[\sum_{n=p+1}^N \left(|e_p^f[n]|^2 + |e_p^b[n]|^2 \right) \right] \quad (12)$$

【0046】(g) 指数関数的に重み付けされた移動平均(Exponentially Weighted Moving Average)

(i) 制御統計

指数重み付け移動平均(EWMA)制御統計値は、次の*

$$EWMA_t = \max \{ (1 - \lambda) EWMA_{t-1} + \lambda \ln [\rho_{normalized}^{fb}], 0 \} \quad (13)$$

【0048】ここでEWMA₀ = 0であり、EWMA_t = 時間tでの予測EWMA値(新しいEWMA)であ

の順序を選択し、誤差分散は、処理の予測不可能な部分の力と、ARパラメータを推定する際の最大誤差を表す量との総和である。AR処理のFPEは、式(6)のように定義される。

【0036】

【数4】

$$FPE[p] = \hat{\rho}_p \left(\frac{N + (p+1)}{N - (p+1)} \right) \quad (6)$$

【0037】

【外1】

(f) 修正した共分散方法

修正した共分散法のp番目の前後線形予測誤差は、ベクトルスカラー積として表してもよい。

【0043】

【数7】

$$e_p^f[n] = x_p^T[n] a_p^{fb} \quad (9)$$

$$e_p^b[n] = x_p^T[n] J a_p^{fb}, \quad (10)$$

【0044】ここでデータベクトル $x_p[n]$ と線形予測係数ベクトル a_p^{fb} は、次のように定義されるが、Jは、(p+1) × (p+1)の反射マトリックスである。計測されたデータサンプル×[1], ..., x[N]に基づいて、修正された共分散方法は、前後線形予測二乗誤差の平均値を最小にする。

【0045】

【数8】

*ように定義される。

【0047】

【数9】

り、EWMA_{t-1} は時間 t-1 での予測 EWMA 値 (古い EWMA) である。[f^{fb}_{normalized}] は、時間 t で実測された値のサンプル分散であり、λ は、一定して 0 < λ ≤ 1 を満足する値であり、EWMA のメモリの深さを決定する。

(i i) 一定重み

EWMA は式 (14) のように表すことができる。ここで w_i は重みであり、w_i = λ (1-λ)^{t-1} である。

【0049】

【数10】

$$Y_{t-1} = \sum_{i=0}^t w_i Y_i \quad (14)$$

【0050】

【外2】

重みの総和は、 $\sum_{i=0}^t w_i = 1$ であり、定数 λ は、EWMA 統計の“メモリ”を決定する。即ち、λ は、重みの減衰率を決定し、情報量は、過去のデータから再収集される。λ が 1 に近づくにつれて、w_i は、1 に近づき、 \hat{y}_{t-1} は、最も新しい実測値 y_t とほぼ等しくなる。一方、λ が 0 に近づくにつれて、最も新しい実測値は、重みが軽くなり、先の実測値は、ほぼ等しい重みを有する。

【0051】 (i i i) 制御上限値

* 【0052】

EWMA 統計の制御上限値は、次の式の通りである。 * 【数11】

$$UCL = \mu_{p^{fb}} + 4\sigma_{p^{fb}} \quad (15)$$

$$\mu_{p^{fb}} = \frac{1}{n} \sum_{i=1}^n \mu_{p_i^{fb}}, \quad (16)$$

$$\sigma_{p^{fb}} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n \rho_i^{fb} - \mu_{p_i^{fb}}}, \quad (17)$$

【0053】ここで n は、正常な機械状態のもとで最初に収集されたデータ集合の数である。

(i v) EWMA 特性

EWMA は、データが古くなるにつれて、データに対する重みを軽くする特性を有する統計値である。EWMA チャートは、プロセス標準分布 (Crowder, S., et al, Journal of Quality Technology 24(1):12-21 1992) を参照) における小さな率の増加分を素早く検知できる能力に関して範囲チャート、即ち s² よりも優れたいうことのために選択されてきた。更に、EWMA は、プロットしやすく、解釈しやすく、制御限界値を得やすい。EWMA を使用する主な利点は、動的処理制御の機構を形成することである。プロセスを制御するためには、プロセスが次の時間の段階となるのはどこであるかを予測することは有意義である。予測が、あまりにも大きすぎる目標から将来の分布を表す場合には、電子機械制御システム、或いはプロセスオペレータは、予測を目標と等しくさせる補修的な作動をとることができる。製造において、開いた経過記録に基づいた予測は、フィードバック制御ループを開始し、プロセスを調整する (ボックス G. 他の実験者のための統計学を参照)。

【0054】ラムダ (λ) は、EWMA 統計値のメモリを決定する。即ち、λ は、重みの減衰率と、これによる経過データから固定された情報量を決定する。1 の選択は、任意的なものであり、0.7 の最も小さい予測分散

(誤差) を形成するように経験的に選択された。式 (13) は、対数を使用することができる。振動データの有意な提示は、診断を行い、機械の実際の機械状態を正確に判定するためには重要である。対数メモリは、機械の振動行動 (Archmbault, R., "Getting More Out of Vibration Signals: using the logarithmic Scale, " Proceedings of the 1st International Machinery Monitoring and Diagnostics Conference, Las Vegas, Nevada, 1989, pp. 567-57 を参照) により近いものとして代替されるものである。正常な分布データの分散に推論を遂行する (ボックス, G., 他 "実験者のための統計学" を参照) ときに、サンプル分散のログが使用されるべきである。理由の一つは、サンプル分散のログが、サンプル分散よりも正常に分布されるということである。また 1/n (p^{fb}) の分離は、s² とは独立しており、サンプルサイズ n にのみ依る。

【0055】s² における増加は、ログガンマ分布 (1/n (p^{fb}) の分布) の位置パラメータにおける増加に対応する。このように、基準となる処理標準分布の増加によりプロットされた EWMA 値の平均レベルを増加しなければならない。上述したようにこの簡潔さと特性のために、ログ変換は適切な変換であると考えられる。回転機械上に収集された振動信号は、非常に複雑なものなので、機械上に与えられた点で計測された振動信号は、各伝達通路によって修正された機械に加えられる内側の総

量であるときに、対数目盛りは、関連する全てのデータを表示する大きな範囲を形成する (Archambault, R., "Getting More out of Vibration Signals: Using the Logarithmic scale, "Proceedings of the 1st International Machinery Monitoring and Diagnostics Conference, Las Vegas, Nevada, 1989, pp. 567-571を参照)。

B. 詳細な作動説明

図21は、本発明に係るEWMAを計算するのに使用された方法論の詳細なフローチャートである。即ち、機械状態を監視し、診断する方法論の概略である。最初に、タイムシリーズデータ (例えば、振動信号) は、ブロック1910に見られるように、正常機械状態における物理的機械 (研究所での設定における) から集められる。好ましい実施例において、各データ集合は1000データポイントからなる。本発明は、機械状態に制限されず、当業者にとって明らかなように、処理にまで及ぶ。

【0056】データ収集は、次のセットアップを用いて導かれる。即ち、これらセットアップは、ドライブベルトによって軸に接続されたDCモータ、軸の各端部に取りつけられ、スチール板に固定された二つの円筒形ピローブロックベアリング、収集された生振動信号を表示するオシロスコープ、信号を拡大する増幅器及びDT2821-G-8DIデータ獲得ボードである。振動信号は、ベアリングハウジングに取りつけられた328C04PCB加速器を用いてベアリングから収集された。加速器は、出力が、加速、即ちよりわかりやすく記載すると、機械内の内力に比例するトランスデューサである。加速レベルが、高い場合には、内力も高い。力は、振動、更には過度の磨耗及び早期故障の一因である。加速計、対周波数の感知性反応 (振幅) は、図22に示されている。加速計は、丈夫さに優れていること、周波数反応が大きいこと、動的範囲が大きいといった理由のために、機械状態監視において好ましいトランスデューサである。加速計は、大きな振動によって損傷をうけることなく非常に小さな振動を検知することができ、出力は、内部損失、及びベアリング故障を検知するための高周波数感知性の一因である力に比例する。

【0057】次に、適切なARモデルが (即ち、収集された振動データを適切に示す) は、式 (6)、式

(7)、式 (8) に定義された基準を用いて選択される。ブロック1920でわかるように、適当なAR順序が選択される。正常な状態に対して、正常なAR順序が選択された後に、ARモデルは、正常な機械状態のもとで収集されたデータ集合のそれぞれごとに、即ちブロック1930と1935に示したように、第一番目のパラメータ (θ_{i1})、第二番目のパラメータ (θ_{i2}) のように、 i が1、2、 \dots 、 n のデータ集合に対してP番目パラメータ (θ_{ip}) までのデータ集合ごとに生成される。ブロック1950と1955において示したよう

に、平均値は、ブロック1930と1935内に形成されたARモデルにより、第一番目のARパラメータからp番目のARパラメータまで計算される。この計算は、研究所での設定において定義された状態のもとで、正常機械状態を表すモデルを定義するためになされる。モデルが、正常機械状態に対して構成されると、新しいデータが異常機械状態のために収集される。次いで、現在の状態で集められたデータ集合にいかにか正常モデルがあるかということを示すものとして、ブロック1950と1955内に見つけられた正常モデルに異常振動信号が適合される。

【0058】ブロック1970と1975に示したように、正常モデルへのデータの適合性を計測するために前後予測誤差が、データの、 $p^{fb}_{normalized}$ 値を決定するように計算される。このプロセスは、上述のセクション2 (A) (f) に記載される (即ち、修正した共分散方法)。本発明の目的は、正常な機械状態からいかなる分布をも検知できるということから、正規化は、正常な機械の状態に基づく。正規化は、同じデータを含む全ての可能なだけの収集、或いは集合を示すのに使用され、作動速度にかかわらず機械の現在と先のデータが重なりあうようにする。更に、正規化は、各特定の機械タイプごとに平均データファイルを形成できる。わずかに異なる作動速度で異なる時間ととられた、多くの区別された機械に対して振動シグネチャは、統計的に積み重ねられて、平均された狭いバンドスペクトルの単一集合によって表すことができる (ワット、W.、他の第一回国際機械監視及び診断会議の議事録のページ637-643に記載の“オーダ正規化振動データポータブルオートメータ機械状態診断プログラム”を参照)。機械の振動シグネチャが重要であるかどうかを判定するために、現在の状態は、 p^{fb} 値を通して正常状態と比較される。

【0059】ブロック1970とブロック1975で見られた p^{fb} 値が与えられると、ブロック1980でみられるように指数関数的に重み付けされた移動平均 (EWMA) 統計が、 $\lambda = 0.7$ で計算される。計算されたEWMA統計は、全体の機械状態を示すものあり、制御上限 (UCL) (セクション2 (G) (iii)) で記載した) と比較され、機械が制御状態であるか、或いは制御されない状態であるかを判定する。この段階はブロック1990と1995に示す。EWMA値がUCLを越える場合に、異常機械状態が存在し、作動を開始しなければならないという信号となる。

C. データ解析

下記の記載は、上述に記載した発明を研究所において実際の機械に適用した結果である。異なるデータセットでわずかに異なる結果となるが、本明細書で記載した原理と方法論は同様に存在する。機械からデータを収集した後に、上述した修正された共分散法と三つの方法が用いられ適切なARモデルを決定し、正常な機械状態を適

切に表す。好ましい実施例において、AEモデルの最も適切な順序、33であり、連続した長さ(1000)に対するAR順序率は、0.033である。連続した長さに対してAR順序率が大きくなる状態で周波数バイアスとラインスプリットが増大するので、この値は小さいのが好ましい。

【0060】好ましい実施例において、正常状態に対して正常なモデルが形成されると、振動データは、三つの異常作動状態、即ち不整列、ベアリングの弛み、及び汚損したベアリングの状態で集められる。表1のよう *10

表2の各セルの上部の数は、研究所内で収集された実データに基づいて観察された最低と最高のEWMA統計を表す。セルの下部の数は、収集されたデータの統計に基づいており、下部境界の $\mu_{p,lb} = 4\sigma_{p,lb}$ 上部境界の $\mu_{p,ub} = 4\sigma_{p,ub}$ を用いて計算される。ここで $\mu_{p,lb}$ は、各機械の状態のEWMA統計値の平均値である。即ち、
$$\mu_{p,lb} = \frac{1}{n} \left[\sum_{i=1}^n \rho_i^{fb} \right],$$
 ここでnは、集められたサンプルの数である。

標準偏差は、 $\mu_{p,lb}$ とともに各ベアリングの状態で決定される。標準偏差は、次の式(18)によって決定される。

【0062】

※20※【数12】

$$\sigma_{p,lb} = \sqrt{\frac{1}{n} \left[\sum_{i=1}^n (\rho_i^{fb} - \mu_{p,lb})^2 \right]} \quad (18)$$

【0063】表2において、異常状態(不整列、汚れ、弛み)に対するEWMA値の上下境界線は、表1の正常状態で計算された最低及び最高EWMA統計と、異常状態の分散とに基づいて計算される。例えば、正常状態において、集められた8個のデータ集合に対する最低最高★

*に、四つの状態のうち一つの状態で集められた各データ集合毎に、最低と最高分散値が決定される。これらの分散は、正常状態(0.00000048582)のもとで分散を平均分散で割ることによって正規化され、各機械状態ごとに最低と最高分散の双方に対して分散自然対数をとる。表2からわかるように、分散値は、EWMAの上下の境界線を決定するのに用いられる。

【0061】

【外3】

★EWMA値は、連続した0.000000と0.126535であった。式(13)を参照すると、EWMA統計は、次のように計算される。

【0064】

【数13】

$$EWMA_t = \max \{ (1-\lambda) EWMA_{t-1} + \lambda \ln \rho_{normalized}^{fb}, 0 \}$$

【0065】

☆ ☆【表1】

表1

正常な機械状態と3つの異常機械状態の計算された“正規化”分散値

統計値	平均値	標準偏差
状態	$\mu_{p,lb}$	$\sigma_{p,lb}$
正常	0.100081	0.124959
不整列	2.561171	0.116305
汚損	5.002439	0.302079
ゆるみ	3.449739	0.125359

【0066】不整列状態において、例えば、起こりうる最低EWMA統計値は、不整列状態の最低分散と正常状態の最低EWMA統計値を用いて計算される。同様に、起こりうる最高EWMAは、不整列状態の最高分散と正◆

◆常状態の最高EWMA統計値を用いて計算される。

【0067】

【表2】

正常機械状態と3つの異常機械状態の計算されたEWMA統計値

EWMA統計値

状態	下部境界	上部境界
正常	0.000000 (0.000000)	0.134323 (0.496657)

27		28
不整列	1. 165905 (1. 072859)	1. 315764 (1. 501256)
汚損	2. 283083 (2. 201966)	2. 487441 (2. 709934)
ゆるみ	1. 835429 (1. 740603)	1. 975226 (2. 162600)

【0068】

* * 【表3】

正常機械状態と3つの異常機械状態の計算されたEWMA統計値

状態	最低EWMA	最高EWMA
正常	0. 0000	0. 4967
不整列	1. 0729	1. 5013
汚損	2. 2020	2. 7099
ゆるみ	1. 7406	2. 1626

表1乃至3の数を微分するのに実施された特定の計算は、Spoerre, J.K., "Machine Performance Monitoring and Fault Classification Using an Exponentially Moving Average Scheme," Masters, Thesis, The University of Iowa, May 1993 に見ることができる。上記で与えられた各作動状態ごとの値の範囲は、異なる機械状態間で重なり合うことなく決定した。図23は、EWMA技術を使用する診断及び監視処理手順を示す。最初に、EWMA統計値は、ブロック2105に示すように、0. 0に設定される。次いで、上述した処理手順を用いて、EWMA統計値はブロック2110のように計算される。次に、EWMA統計値は、正常状態の上限に対してチェックされる。例として上記では、0. 4967である。

【0069】EWMA統計値が、上限値より下になる場合には、ブロック2110に示すように機械は、正常に作動する。この場合、処理手順は、ブロック2110に戻る。しかしながら、EWMA統計値が上限値を越える場合には、ブロック2130に示すように潜在的な異常状態が存在する。表2に基づいて、ブロック2140、2150、及び2160のそれぞれは、異なる異常状態を表す。即ち、EWMA統計値は、1. 1と1. 5の間となり、異常状態は、不整列である。EWMA統計が1. 7と2. 2の間の場合には、異常状態は、ベアリングの弛みである。EWMA統計値が2. 2と2. 7の間である場合には、異常状態は、汚損である。もちろん、他の異常状態を上述の処理手順に従って、かつ適切なEWMA統計値を判定することによって検知することができる。異常状態が、検知されると、手順2100は、ブロック2170、2180及び2190に示すように、ユーザインタフェース150を介して検知された故障をプリントする。このとき、オペレータは、ブロック2195に示すように機械に対する問題を修正し、EWMA統計値を0. 0（即ち正常状態）にリセットする。

【0070】図24は、EWMAチャートを表す。EWMAチャートは、特定の機械状態の位置を表す、バンド

2210—2240にわけることができる。正常状態は、2240に示されており、異常状態は、バンド2210—2230に示されている。正常機械状態を特徴づけるためにARパラメータモデルを展開することによって、EWMA制御統計値は、機械が正常状態（“制御において”）あるいは、異常状態（“制御停止”）であるかどうかを識別する。ベアリング状態が異常となり、悪化するとき、EWMA制御チャートのプロットは、制御限界に近くなり、上限値となる傾向を示す。実際には、EWMA制御統計値は、異常状態が修正されない場合には、正常制限を越えている。与えられた機械の状態に対する信号の振幅平均と、平均EWMA統計値との間には正の相関関係があることが定義された。平均振幅が増大するにつれて、EWMA値は、増大する。このことは、EWMA統計値が振幅によって変化しやすいということを意味する。ベアリングや他の機械部品が故障の最初の段階となるとときに、振幅が増大するので、EWMA技術は、欠陥がひとたび起きると、振幅の小さな変化を検知できる能力を有する。

【0071】更に、正常な状態で形成された分散からの時間tでの分散の偏差が、現在のベアリング状態を表すものと示されてきた。この偏差が、ほぼゼロの場合には、ベアリングは、正常状態で作動する。しかしながら、この値が、ゼロと全く異なる場合には、コイルがはずれた状態であり、修正のための作動が必要となる。

3. パラメトリックモデリング及びART2アプローチ図3は、本発明の骨組みを示す。これは三つのモジュール、即ちパラメトリックモデル310、正規化処理320、及びART2神経回路網225から構成される。好ましい実施例において、自動回帰（AR）パラメトリックモデルは、ART2神経回路網225との組合せで使用される。しかしながら、移動平均の自動回帰（ARMA）パラメトリックモデルは、ART2神経回路網225との組合せで使用される。しかしながら、自動回帰移動平均の（ARMA）モデルも使用することができる。ARモデルとARMAモデルは公知である。パラメ

トリックモデル 310 は、物理的機械から収集された生振動信号、あるいは、検査における処理に適応するように用いられる。振動信号にパラメータモデル 310 を適合させた後に、一組のパラメータ 315 が得られる。しかしながらこの点において、予め処理することなく、パラメータ 315 は、ART2 回路網 225 に給送されることができない。なぜならば、パラメータ 315 は、ART2 回路網 225 が認識することのできない意味負の値を含んでいるからである。このため、ART2 回路網 225 が、適切な入力で正確に機能することができるように、正規化処理 320 が適応される。

【0072】正規化処理 320 は、2つの段階を要求する。第一に、各パラメータ 315 を二つのパラメータ、即ち正と負に分ける。パラメータ 315 が正值を有する場合には、負の部分はゼロにする。逆も同じである。第二に、パラメータ 315 のスケールリングは、各パラメータ 315 を最大パラメータ値で割ることによって生じる。残余分散は、正部分のみしか含まない。その値は、いつも正であるからである。しかしながら、分散は、最大残余分散によって割らなければならない。n パラメータを有する ARMA 或いは AR モデルは、ART2 入力層内に $2n+1$ の入力ノードを必要とする。例えば、ARMA (3, 2) モデル ($n=5$) の ART2 回路網 225 は 11 の入力ノードを要求する。次のパラメータと残余分散を備えた、ARMA (3, 2) モデルの ART2 回路網 225 が図 18 に示されている。

【0073】

【数 14】

$$\begin{aligned}\phi_1 &= 1.7592 \\ \phi_2 &= -1.7289 \\ \phi_3 &= 0.8364 \\ \theta_1 &= -1.0300 \\ \theta_2 &= -0.7562 \\ \sigma_e &= 0.3838\end{aligned}$$

【0074】正と負の部分両方の最大パラメータ値が 2 であると、最大残余分散は、1 である。例えば、 ϕ_1 を取り上げると、 ϕ_1 の値が正であるために、負の部分は、0 に設定される。正部分は、最大パラメータ値 2 で割られて、0.8796 が得られる。残余分散では、最大分散が 1 であるためにその値は同じままである。回路網のトレーニングの間、ART2 回路網 225 は、入力パターン、即ち正規化パラメータ 325 が設けられる。その結果、回路網は、故障分類を自己編成し、ついには入力パターンを終えることになる。最後には、後の診断*

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + E_t \quad (19)$$

【0076】

※ ※ 【外 4】

ここで、 X_t は、一連の時間であり、 ϕ_i は、AR パラメータであり、 p は、AR モデルの順序であり、 E_t は、NID (0, σ_e^2) を備えた残余である。

*に使用するために、最終的なトップダウン重み (T_{ij}) とボトムアップ重み (B_{ij}) がセーブされる。故障診断の間、各入力パターンが ART2 回路網 225 に与えられる。 F_2 層 240 内の各ノードは、特定の故障分類を表す。警戒テスト 250 を通過する F_2 層 240 のノードは、ART2 回路網 225 の出力 335 となる。先に述べたように、修正した ARTMAP 回路網 200 の訓練の間、インプットパターン 210 と所望の出力パターン 220 双方は、修正 ARTMAP 回路網 200 に与えられなければならない。各入力パターン 210 の集合と所望の出力パターン 220 が用いられて、修正 ARTMAP 回路網 200 を別個に訓練する。このことは、修正 ARTMAP 回路網 200 は段階的に訓練されることを意味する。好ましい実施例において、入力パターン 210 は、振動スペクトルの 200 個のデータポイントからなる。所望の出力パターン 220 は、二進ベクトルであり、ベクトルの各ノードは、特定の機械状態に対応する。

4. 故障診断：方法論と具現

このセクションでは、本発明に従って開発された故障診断システム 400 を説明する。このシステムで使用された方法論は、このセクション全体に及ぶ。セクション 4.1 では、データ予備処理の自動回帰モデリング技術の適用について説明する。セクション 4.2 では、故障診断回路網の展開を記載する。セクション 4.3 において、物理的なベアリングモデルと公知のパターンのフェジ理論ベースの故障仮説論と試験手順を説明する。

【0075】4.1 自動回帰 (AR) モデル

自動回帰 (AR) 技術は、信号が物理的機械又は処理に接続された一組のセンサを通して捕捉されたタイムドメインからこの信号を周波数ドメインに変換する方法である。一般的に、これはフーリエ変換を用いてなされる。信号を処理するためにパラメトリックモデルを使用する利点は、データ量を動的に減少させることができ、信号の重要な特性を依然として保持していることである。データが減少する結果として、神経回路網の診断と訓練時間は、大幅に短縮される。入力データ数が 200 から 2400 に増加する場合に、訓練時間は、約 10 倍に増加し診断時間は約 6 倍に増加するために、データの減少は臨界的である。特に複数センサがリアルタイムモードで使用するとき、含まれたデータ量が増大するからである。本発明は、オンライン信号処理の AR モデルを実現する。AR モデルの数学的形狀を式 (19) に示す。

【0077】AR モデルの順序は、Lin C.C. による Master's Thesis, Department of Industrial Engineering

g. The University of Iowa の "Classification of Autoregressive Spectral Estimated signal Patterns Using

g an Adaptive Resonance Theory (ART) ”に記載されたアプローチで決定される。最高の予測誤差 (FPE) アカイク情報基準 (AIC) レベルを用いて順序を選択する。FPEとAICは次の式で表される。

【0078】

【数15】

$$FPE(p) = \sigma_p^2 \left(\frac{N + (p+1)}{N - (p+1)} \right) \quad (20)$$

$$AIC(p) = N \ln(\sigma_p^2) + p \ln(N) \quad (21) \quad 10$$

※

ここでNは、データサンプルの数であり、pは、AR順序であり、 σ_p^2 は、順序pでの推定線形予測誤差分散である。決定されたAR順序は、固定され、次いで、ARモデルを知覚データに適合させ、ARパラメータ315を形成する。正規化されると、(上述したように) ARパラメータ315を、修正したARTMAP回路網への入力として用いることができる。

【0080】4. 2 故障診断回路網

故障診断回路網 (即ち修正ARTMAP回路網) を使用する目的は、機械故障を素早くかつ正確に診断することである。修正ARTMAP回路網200は、段階的な学習の独特な特性を有する、効率的でかつ強固なパラダイムである。後方伝搬のような、他の一般的な神経回路網とは異なり、修正ARTMAP回路網200は、新しいパターンが発見されるごとに新旧全てのパターンで訓練する必要はない。修正されたARTMAP200の機構は、次のセクションで述べる。

4. 2. 1 修正ARTMAP回路網

修正ARTMAP神経回路網200は、予測成功に基づいて、任意に順序付けられたベクトルを認識カテゴリーに分類することと自律的に学習するART (適応共振論) 回路網の延長である。図1を参照して記載したように、ARTMAP神経回路網100は、それぞれが認識カテゴリーを発生する一対のARTモジュール110、120と、一対の認識カテゴリー間の写像を制御する写像フィールド130とから構成されている非監視学習システムである。好ましい実施例において、ARTMAP神経回路網は、一個の入力パターン (即ち、ARパラメータ) だけを使用する。このように、監視された学習を遂行するために図1に示すARTMAP神経回路網は修正される。図2は、第二ARTモジュールが、目標出力220によって置換されている、修正ARTMAP回路網200を示す。回路網200において、目標出力220は、ユーザーから与えられる。ART2神経回路網アーキテクチャ225は、アナログ入力パターン (例えばARパラメータ) を処理するためのARTモジュールを基本とするものとして選択される。 ※

$$T_{i,j} = 0$$

$$B_{i,j} = 1 \div 0.2 * \sqrt{N}$$

※【0079】

【外5】

※【0081】詳細に、ART2神経回路網アーキテクチャが好ましい実施例において使用される。振動と音信号が修正ARTMAP神経回路網200への入力として採用され、振動あるいは音信号のエネルギーレベルは、連続アナログ信号であるからである。しかしながら、当業者にとって明白なように、音信号以外の信号も修正ARTMAP神経回路網200に適応させることができる。更に、本発明は、二入力パターン任意のシーケンスを修正ARTMAP神経回路網200への入力として使用する場合には、本発明をART1神経回路網アーキテクチャとともに使とすることができる。この修正ARTMAP回路網200において、ART2回路網120は、二つの層、即ちF₁層230とF₂層240を有する。図4を参照すると、ART2回路網のF₁層230は、回路網に信号をノイズから分離して活動化信号のコントラストを高めることを可能にする三つの処理レベル及び幾つかのゲイン制御システムを含む。一般的に、各レベルは、二つの計算を遂行する。即ち、そのレベルへのフィールド内及びフィールド間入力を積分して積分された活動化信号を発生する計算と、その積分された活動化信号を正規化する計算である。満たされた円は、積分された活動化信号を正規化するゲイン制御システムである。

【0082】以下に、図4、図5、図6を参照して、修正回路網の訓練について説明する。図5、図6は、修正ARTMAP回路網200を訓練するのに使用する手順のフローチャートである。ブロック505で示すように、修正ARTMAP神経回路網200の訓練を初期化する前に、次のパラメータが初期化される。

$$(22)$$

$$(23)$$

$0 \leq i \leq N-1$ 、ここでNは、入力ベクトル210のディメンションである。 $0 \leq i \leq N-1$ 、ここでMは、 F_2 ノードの数である。 $w_i = x_i = v_i = u_i = q_i = p_i = 0$ 、及びa、b、c、d、e、 θ 及び ρ をセット。ブロック510に示すように、学習されるべき入力パターンが修正ARTMAP神経回路網200に提示される。次に、ブロック515に示すように F_1 層230のノード間の活性化信号が発生する。 F_1 層230の低レベルで、ベクトル w_i は、フィールド内入力ベクトル*

$$v_i = f(x_i) + b f(q_i) \quad (26)$$

$$u_i = v_i / (e + \|v\|) \quad (27)$$

$$q_i = q_i / (e + \|p\|) \quad (28)$$

$$p_i = u_i + \sum_j g(j) T_{ji} \quad (29)$$

ここでbは定数であり、 $g(j)$ は、 F_2 層240のj番目のノードの動作であり、 T_{ji} は、 F_2 層240のj番目ノードと F_1 層230でのi番目のノードあとの間※

$$0 \leq x < \theta \text{ ならば、} f(x) = 0、$$

$$x \geq \theta \text{ ならば、} f(x) = 0$$

ここで θ はしきい値である。ブロック520に示すように、 F_2 層240内のノードが F_1 層230からの入力20信号を受信すると(ボトムアップ重み B_{ij} を介して)、★

$$\mu_j = \sum_i P_i B_{ij}$$

ここで、 B_{ij} は、ボトムアップ重みである。次いでブロック530に示すように、最大整合スコアを備えた F_2 層j番目の F_2 ノードが活動する場合、それ以外の場合、

ここでdは0と1の間の定数である。この点において、 F_2 層240活動は、 F_1 層230に戻り伝播される。次に、ブロック535に示すように、警戒試験250が◆

$$r_i = (u_i + c p_i) / (e + \|u\| + \|c p\|) \quad (33)$$

$$P / (e + \|r\|) > 1? \quad (34)$$

ここでcは、 $0 < p < 1$ の定数である。整合が警戒試験250を通ることに失敗する場合には、ブロック545に示すように、リセット260が F_2 層240に送られ、 F_2 層240に力を加えられ、 F_2 層内の選択されたノードを非活動化し、次の最良の整合を探索する。整合が警*

$$B_{ij*}(t+1) = d [P_i - B_{ij*}(t)] \quad (35)$$

$$T_{j*i}(t+1) = d [P_i - T_{j*i}(t)] \quad (36)$$

ここでj*は F_2 層240内のノードから選択される。ブロック550に示すように、警戒試験を通る場合には、ボトムアップ重みとトップダウン重みが更新される。ARTモジュール120に入力ベクトル210が提示されると、警戒試験250を通過する F_2 層240内※

$$X = w_{j*}$$

写像フィールド130で、第二の警戒試験140が実施されて、ブロック560に示すように、 F_2 層240(X)から予測された出力と目標出力パターン(Y)との整合レベルを決定する。XとYとの不整合は、写像フ★

$$\|X\| / \|Y\| < P'$$

ここに、 P' は、連想メモリ警戒パラメータ240であ 50

* I_i とフィールド間フィードバック信号 $a u_i$ との和である。即ち、 $w_i = I_i + a u_i$ ここで、iは、 F_1 層230でのi番目のノードであり、aは定数である。ベクトル w_i が求められると、以下の式で正規化されて x_i が求められる。

$$[0083] \quad x_i = w_i / (e + \|w\|)$$

ここでeは、ゼロに近い定数であり、 $\|w\|$ は、ベクトルwの L_2 ノルムを示す。 F_1 層230の残余の活性化は、以下の式に従って計算される。

※のトップダウン重みである。式(26)の線形信号関数fは、

$$(30)$$

★ F_2 層240内のノードの整合スコアは、以下の式によって計算される。

$$[0084] \quad (31)$$

☆層240のノードが活動化される。 F_2 層240の活動は、以下の式で表される。

$$g(j) = d \\ g(j) = 0 \quad (32)$$

◆遂行されて、トップダウン信号が入力パターン210に整合するかどうかを判定される。警戒信号250は、以下の式で与えられる。

$$(33)$$

$$(34)$$

*警戒信号250を通る場合は、ボトムアップ重み(B_{ij})とトップダウン重み(T_{ji})は以下の式から合わされる。

$$[0085]$$

$$(35)$$

$$(36)$$

※のノードを選択する。ついで、ブロック555に示すように F_2 層240活動は、 F_2 層240と写像フィールド130との間の重み付け付き接続(B_{jk})を介して写像フィールド130に伝播される。 F_2 層240から受信した信号は以下の式で計算される。

$$(37)$$

★フィールドリセット270をトリガして、基本ARTモジュール120に送られる。これは、次の状態が維持されればいつでも生じる。

$$[0086]$$

$$(38)$$

る。写像フィールドリセット270が生じる場合には、

ブロック570に示すように、基本ARTモジュール120の警戒250が高められて、システム200が誤差を繰返さないようにする。この点において、ブロック545に示すようにリセット260は、F₂層240に送られて、F₂層240に力を加えて次の最良整合を見いだす。この処理は第二警戒試験140が成功するまで続*

$$\omega_{jmk} = Y_k$$

ブロック580に、トップダウン重み(T_{ji})とボトムアップ重み(B_{ji})を示す。ボトムアップ重みとトップダウン重みに対する重み適合処理は、各訓練パターン毎に繰り返して行われる。何故ならば、各更新が繰り返された後に、pで表される、正規化された入力ベクトル210も正規化されるからである。次いで、F₁層230内の新しいベクトルpが、次の重み更新反復(式(35)と式(36)を参照)のために用いられる。

【0087】訓練の段階中、入力ベクトル210(即ち、ARパラメータ)と目標出力ベクトル220(即ち、故障分類)が回路網に提示される。次いで、回路網は、上述の手順に従って、入力ベクトル220と目標出力ベクトル220との間の連想の学習を開始する。診断の段階中、入力ベクトル210のみが回路網に提示される。F₁警戒試験250を通過するF₂層240内のノードは、回路網の出力(即ち、予測した故障分類)を表*

$$B_{ji*} = 1 / (1 - d) \sqrt{N}$$

$$T_{jmk} = 0$$

Nは、F₁層230内のノードの数であり、dは0と1の間の定数である。写像フィールド230の重みは、次★

$$\omega_{jmk} = 0$$

4. 2. 2 修正ARTMAP回路網による診断

図6に回路網診断手順を示す。上述した手順を使用して、修正ARTMAP回路網200が訓練された後に、診断が行われる。ブロック610に示すように、修正ARTMAP回路網200は、最初にユーザから入力データを獲得し、或いは物理的機械或いはプロセスからデータを直接獲得する。入力を受信した後に、ブロック620に示すようにART2回路網225は、仮に診断を行う。仮の診断が第一の警戒試験250を通過する場合には、ブロック630に示すように診断結果がユーザに報告される。ブロック640において、ユーザは、回路網診断を確認するように要求される。診断が正しければ、ブロック690及び680でそれぞれ示すように、ユーザは、現在の入力パターンで回路網を訓練するか、即ち回路網にその重みを適合させるか、或いは、診断プロセスを放棄するかのいずれかを選択する。診断が、正しくない場合には、二つのオプションが考えられる。ブロック660に示すように、ユーザが正しい故障分類を知っている場合には、正しい故障分類を指定するか、或いはユーザは、回路網に他の診断を行うように要求する(即ちブロック620に戻る)することができる。

【0089】システムを試験するために、全部で48組

*けられる。第二警戒試験140が通ると、F₁層230とF₂層240との間のトップダウン重み(T_{ji})とトップアップ重み(B_{ji})が式(35)と(36)に従って適合され、F₂層240と写像フィールド130との間の重みは、次の式によって更新される。

$$(39)$$

※す。修正ARTMAP回路網200の他の独自の機能は、“未学習(unlearn)”能力である。回路網学習能力とは逆に、未学習は、回路網によって先に学習した望ましくない知識を取り除く。このことは、先に学習したパターンが誤ったパターンであるときには、非常に有効である。このような状態において、この間違いを訂正するための一つの方法は、望ましくないパターン以外のパターンを保持することであり、これは実行容易なことではない。パターンを未学習にするより効率的な方法は、正しくないパターンを無視する回路網の重みをリセットすることである。一般的に、“未学習”手順は、上述した訓練手順と同じである。F₂ノードが警戒テスト240、140の両方を通ると、回路網重みは次の式に適合する。

【0088】

$$(40)$$

$$(41)$$

★の式により更新される。

$$(42)$$

のデータセットと三つの異なる機械状態(即ち、正常、ベアリング故障、不整列)が用いられて、二つに分けられる。二つの部分とは、訓練用の15データ集合と、試験用のデータ集合である。警戒値と訓練セットサイズの効果も調査された。警戒が0.3、0.5、0.7、0.8或いは0.9に設定したときには、回路網の性能は同一のままである。しかしながら、訓練セットサイズが3に設定されるときに(各カテゴリーに対して一つ)、回路網の精度は、約98%であった。訓練用セットサイズが6に増大すると(各カテゴリーごとに2つ)、回路網は、全ての試験データを正確に識別することができた。

4. 3 未知パターンの仮説検定

上述したように、機械故障診断に使用された主な技術は、修正ARTMAP回路網200(或いFDN)である。先に述べたように、回路網は、例で最初に訓練され、パターンが例のうちの一つに類似した特性を有するとき、回路網がそのパターンを認識できるようになる。しかしながら、全体的に新しいパターンが展開されるときがあり、修正ARTMAP回路網200は、先にこのようなパターンを経験しなかった。このような環境のもとで、修正回路網200は“未知パターン”を診断され

るであろう。この問題を解決するために、物理的ベアリングモデルとファジィ論理は、好ましい実施例において混合されて、未知の故障状態を解析して正確に指摘するための仮説検定手順を遂行する。

【0090】機械が新品であり、いかなる経過センサデータば入手できないときには、故障診断回路網の共通のベアリングの欠点の初期訓練データを提供する手段として、物理的ベアリングモデルを使用することができる。ベアリング欠陥振動信号周波数を計算するための論理的な式が付録(A)にリストアップされている。物理的ベアリングモデルは表示のみに使用される。当業者には明白なように、本発明の教示に従って他の物理的モデルを使用してもよい。物理的ベアリングモデルは、複雑な、或いは複数の故障状態のときのために仮説検定機構として使用することもできる。即ち、複雑な問題内の故障推論プロセスは不確かであり、曖昧である。ファジィを考慮するのに最も効率的な用具のにひとつは、ファジィ論理方法である(Li, J. et al., "Fuzzy Cluster Analysis and Fuzzy Pattern Recognition Methods for Formation of Part Families (NAMRC)," Society of Manufacturing Engineers, 1988, pp558-300を参照)。従って、*

$b < x$ の場合には、 $\mu(x) = 1.0$ 、

$a < x \leq b$ の場合には、 $\mu(x) = (x - a) / (b - a)$ 、

$x \leq a$ の場合には、 $\mu(x) = 0.0$

(43)

次いで、ファジィ論理ユニット950は、欠陥の可能性を仮定し、標準パターンと未知の振動信号との間の同一性を比較することによって、この仮説を試験する。パタ※

$$(X_i, X_j) = 1 - \frac{\sum_{k=1}^p m |\mu_k(X_{ik}) - \mu_k(X_{jk})|}{\sum_{k=1}^p (\mu_k(X_{ik}) + \mu_k(X_{jk}))} \quad (44)$$

【0093】ここでpは、パターン内のARパラメータの数であり、mは、サンプル標準パターン間の距離を増大させるための重み付け要素である。1に近い同様なスコアは、二つのパターンが非常に類似していることを意味しており、逆も同じである。上述した仮説検定手順がプログラムされて全ての識別可能な故障可能性をリストアップし、これらの類似性は、ブロック960に示すように、確認をとるためにユーザに示される。

4.4 故障推論エキスパートシステム

好ましい実施例において、診断システム400は、故障推論エキスパートシステム(FRES)を採用する。修正ARTMAP回路網200によって信頼できる状態で検知されなかった、推定されうる異常状態を備えた如何なるデータサンプルも解析のためにFRESに送られる。同様に、修正ARTMAP200が一つの種類以上の故障を推定する場合には(例えば不整列と汚損)データサンプルはFRESに送られる。FRESは、知識ベース、損傷、或いは修理歴、及び故障を判定するための

*本発明の仮説検定機構は、ファジィ論理方法に基づいて行われる。本発明の好ましい実施例に従って採用された、ファジィ論理ベースの仮説検定手順の実行を図10に示す。この手順は、神経回路網200が未知の信号にあうときに生じる。ブロック910に示すように軸速度と同様に、ベアリングの幾何的パラメータを回復させた状態で開始し、付録Aの式を使用して対応するベアリング欠点を計算する。ブロック920に示すように欠陥点信号は、共通振動信号と組み合わせられて、一組の故障シグネチャを形成する。ブロック930に示すように、これらのシグネチャは、ARモデルによって適合され、一組のARパラメータを発生させる。各ベアリング欠陥に対する標準(実際)パターンが、ブロック940に示すように欠陥のための一組のARパラメータを平均化することによって発生する。

【0091】次いで仮説検定は、ブロック950に示すように、次のファジィ論理方法で遂行される。最初に、各標準パターンのパラメータにファジィ親子関係関数を割り当てる。以下に示すように、線形親子関係関数が用いられる。aとbは、パラメータ値の適切な範囲であ

※ X_i と X_j の類似性は以下のように定義される。

【0092】

【数16】

機械使用情報内の規則に対して、識別可能な故障可能性をチェックする。このチェックの結果は、推奨に従ってユーザーインターフェイス450を介して表示される。

【0094】以下に、FRESによって使用された一般的な機械故障のエキスパート規則のリストを上げる。

・一連の周波数が発生した場合、

走行速度の整数分数調波が存在し(1/2、1/3、1/4、・・・、1/n)、高周波数が励起され、波形が切頭されて、平坦になり、機械の状態は、回転障害である。

・振動周波数が、0.42-0.48×RPMを示す場合には、振動が半径方向に存在し、機械状態は、オイル振れ回り不安定さである。

・半径方向における1×RMSが振動スペクトルを抑制する場合には、信号は、位相内にあり、固定され、不均衡のための増幅は、速度の二乗だけ増大し(3×速度増大=9×より高い振動)、機械状態は、力不均衡である。

【0095】・ $1 \times \text{RPM}$ が最も大きな力である場合に、振幅は、速度の2乗であり、信号は 180° ずれて、高い軸方向と半径方向の振動が生じ、機械状態は、結合不均衡である。

・高い $1 \times \text{RPM}$ が軸線方向と半径方向で生じた場合に、軸線方向の読み取りは、位相内にあり、半径方向の読み取りは、非定態であり、半径方向の読み取りは、軸線方向の読み取りよりも低く、機械状態は、片持ち型回転不均衡である。

・軸線方向の位相を備えた高軸線方向振動が 180° に近い場合に、卓越振動は $1 \times \text{RPM}$ 或いは $2 \times \text{RPM}$ であり、機械状態は、曲がった軸である。

・最も大きな振動が $1 \times \text{RPM}$ で生じた場合には、位相読み取りは、 0° 或いは 180° だけ差があり、均衡になり、その結果、一方向の振動が減少するが、半径方向では増大し、機械状態は、同軸回転子である。

【0096】・軸線方向の振動が存在する場合に、振動は、継ぎ手を横切って位相から 180° ずれ、軸線方向の振動は $1 \times \text{RPM}$ と $1 \times \text{RPM}$ で高いが、 $1X$ 、 $2X$ 、或いは $3X$ のいずれも他よりも優勢ではなく、機械状態は、角度的に不整列である。

・卓越振動が、 $2 \times \text{RPM}$ である場合に、調波の複数の $1/2$ 或いは $1/3 \text{ RPM}$ ($.5X$ 、 $1.5X$ 、 $2\%X$ 等)が生じ、振動は、半径方向に生じる。

・振動スペクトルは、単一の周波数であり(正弦波的动作を表す)、振動の振幅は、平方速度に比例して機械状態は、不均衡である。

・半径方向の振動シグネチャが軸線方向の振動シグネチャの 1 と $1/3$ に等しいかそれ以上である場合には、機械状態は、不整列である。

*曲がった軸は、位相を検討することによってのみ認識可能である。

**不均衡は、半径方向にのみ認識可能である。

以下にベアリング故障のエキスパートの規則を述べる

・一連の走行速度の調和(10 から 20)が半径方向に生じる場合に、垂直方向の振幅が、水平振幅に対して高く、振幅は、高調波で減少する傾向にあり、ベアリング状態は、摺動ベアリング磨耗状態である。

【0097】・ $2 \times \text{RPM}$ での振幅が $1 \times \text{RPM}$ の振幅の $1/3$ よりも大きい場合等しい場合には、ベアリング状態はゆるみ状態である。

・相当の軸線方向の振動がある場合には、ねじれ動作のために、上下に約 180° のずれるか、または軸線方向に横から横に計測され、振動が $1 \times \text{RPM}$ と $2 \times \text{RPM}$ で生じ、 $2 \times \text{RPM}$ は、 $1 \times \text{RPM}$ より優位であり、ベアリング状態は、不整列なベアリングである。

・一連の時間信号内でボールパス周波数で、鋭いパルスが生じる場合に、周波数スペクトルは、かなり低い振幅を表示し、機械状態は、ベアリング軌道輪上で、単一のかけら状態である。軸速度に変化が起きて、振動周波数

に変化がない場合には、機械状態は、障害があるか、或いは共振状態である。

・FFTが振動振動を平方波に変換する場合に、ベアリングは相当にゆるんだ状態である。以下にギア故障に対するエキスパート規則を述べる。

【0098】・ギアカみ合わせのパターンが、ギアカみ合わせ周波数で、正弦波、或いは修正正弦波である場合に、振動周波数は、 $1 \times \text{RPM}$ および $2 \times \text{RPM}$ で生じ、ギアカみ合わせ周波数が側帯波であり、全てのピークが低振幅であり、ギアは正常状態である。

・振動周波数が $1 \times \text{RPM}$ である場合に、振動の和と周波数の差は、 $+/-1 \times \text{RPM}$ であり、ギアは、ギアがはずれる状態である。

・側帯波が基本周波数と同じ振幅である場合には、ギアは取替えが必要である。

・ギア自然周波数が、悪いギアの走行速度で、間隔のあった側帯波に沿って励起されるならば、高い振幅側帯波がギアカみ合わせ周波数の回りを囲み、ギアカみ合わせ周波数が生じ、ギアは、歯が磨耗した状態である。

【0099】・ギアカみ合わせ周波数(GEAR MECH FREQUENCY)の回りに高い振幅側帯波が生じた場合に、ギアカみ合わせ周波数(GEAR NATURAL FREQUENCY)が励起され、ギア自然周波数が励起され、GMFとGNFが $1 \times \text{RPM}$ で側帯波され、ギアは、偏心し、がたつく。

・ギアカみ合わせ周波数の第二或いはより高い調波が励起される場合には、高調波が走行速度で側帯波であり、小さな振幅が $1 \times \text{GMF}$ であり、より高い振幅が $2X$ 、或いは $3X \text{ GMF}$ であり、ギアは、不整列な状態である。

・ $1 \times \text{RPM}$ でスパイクが表示され、ギアが均衡を失っているか、或いは歯を失っている状態である。

*ギアカみ合わせ周波数=歯 \times ギア速度

もちろん、当業者は、他のエキスパート規則を実施することができる。即ち、上述で与えられたエキスパート規則は、完全なリストであると考えべきではなく、むしろ本発明の好ましい実施例に使用されたエキスパート規則を例示するものである。

【0100】4.5 故障診断

図16を参照すると、物理的機械、即ち処理が作動して、診断手順が開始される。最初に、ブロック1505に示すように、データ(例えば、振動、温度、圧力)が物理的機械又は工程から獲得される。このデータは、ブロック1505で示すように予め処理される。このデータは、ブロック1510に示すようにARモデルを用いて前処理される。次に、ARモデルから発生したパラメータが用いられて、物理的機械又は工程内の異常状態を検知する。この検知は、ブロック1515に示すように、RMS計測とEWMA法の共分散統計値とに基づいた、インデックスを用いるオンラインでなされる。この段階は、故障診断回路網200のフィルタと考えられ

る。ブロック 1515 で故障が検知されない場合には、故障診断が開始されない。本発明のこの特性がブロック 1520 に示されている。ブロック 1520 は、ブロック 1515 の出力を監視し、機械、即ちプロセスが正常な状態（緑色の状態）、故障のある可能性がある状態（黄色の状態）、或いは診断状態（赤色の状態）で作動しているかどうかをこの出力から判定する。これらの各状態は、暗示的な特性において特定のシステム、或いは当業者にとっては明かなように、作動するプロセスに要求されるように調整することができる。

【0101】機械、即ちプロセスが緑色の状態で作動する場合には、ブロック 1525 に示すように診断システム 400 に接続されたユーザーインターフェイス 450 は、機械、即ちプロセスが通常に作動することを表示する。ブロック 1530 に示すように機械、即ちプロセスは、赤色の状態で作動している場合には、停止する。機械、即ちプロセスを停止した後に、診断が行われる。同様に、RMS と EWMA が黄色の状態を示す場合には、診断が行われる。図 17 を参照すると、ブロック 1535 で示すように黄色或いは赤色状態である場合には、診断が行われる。好ましい実施例において、ブロック 1540 に示すように、付加的な知覚データが検査中の機械、即ちプロセスから獲得される。このことは、要求されない付加的な段階である。故障を検知するために、ブロック 1515 によってオリジナル的に使用されたデータが診断のために使用される。次に、ブロック 1545 に示すようにデータが FDN200（修正 ARTMAP 回路網 200）に与えられる。もちろん FDN200 は、上述したような概論に従って手順を用いて訓練されてきた。判定ブロック 1550 は、FDN200 が診断（即ち、故障を機械又は工程で識別する）を行ったかどうかを判定する。FDN200 が診断を行えないのであれば、ブロック 1555 で示すように物理的機械（或いはプロセス）モデルが適用される。上述したように、正常な作動状態で機械又は工程から得られた正常信号で組み合わされた論理的な既知の式から発生した、欠陥周波数から物理的モデルが発生する。この組合せのために、一組の故障シグネチャを得ることになる。

【0102】次に、ブロック 1560 に示すようにファジィ集合論が故障シグネチャに適用される。FDN200 が診断を行う場合であっても、ファジィ論理は、第二のチェックとして診断に依然として適用される。ファジィ論理は、第一の故障可能性を仮定し、故障シグネチャと、機械及びプロセスからの未知の信号との類似性を比較することによって、この仮説を試験する。更に診断システム 400 は、ブロック 1565 に示すように、識別可能な故障可能性を全て表示する。ブロック 1570 に示すように、これらの識別可能故障が FRES に与えられる。上述したように、FRES は、知識ベース、損傷或いは修復歴、機械使用情報の規則に対して識別可

能故障をチェックし、故障可能性を判定する。このチェックの結果、ブロック 1575 に示すように、推奨に沿ってユーザーインターフェイス 450 を介して表示される。このとき、オペレータは、ブロック 1685 に示すように介入することができる。最後に、データベース 440 は、上述した診断手順から得られた最終結果で更新される。

5. トランスピュータ回路網

好ましい実施例において、本発明は、トランスピュータ回路網上で修正 ARTMAP 回路網 200（或いは FDN）診断と訓練とともに、ファジィ論理ベースの仮説検定手順を行う。より性能の高いコンピュータの要望がかなり高まってきた。これは、センサがより多くのデータを生み出し、システムをより複雑にさせる技術を前進させるためである。今日市場で売られている殆どの全てのコンピュータは、いわゆる連続した、即ちフォンノイマン（Von Neumann）型コンピュータであり、次に開始される前に、各命令は個々に穿孔翻訳され、遂行される。このため、このクラスのコンピュータシステムの速度は、このシステムの CPU 力によって最終的に決定される。

【0103】近年の研究では、PC クラスのマイクロプロセッサに基づく平行式計算は、性能と費用において、ベクトルマシンよりも優れていることを示唆してきた。平行式計算は複数の CPUs を用いており、複数の作業を同時に行う。これら CPUs は、あらゆる方法で互いにリンクされており、広い範囲の平行処理アーキテクチャを行うことができる。トランスピュータクラスとして公知の複数命令ストリーム複数データストリーム（MIMD）（即ち、いくつかの CPUs は、同時に異なるデータ上で異なる命令を遂行する）は、何年にもわたって、特に平行処理を開発してきた。トランスピュータは 32 ビットコンピュータチップであり、それ自身の CPU と位置メモリとを備えた完全なコンピュータである。各トランスピュータは、内部プロセッサの伝達のために四つの連続したリンクを有する。このリンクを通して、トランスピュータは、別のトランスピュータユニットと接続され、高性能のコンカレントシステムを形成する。更に、トランスピュータの回路網は、パイプライン、木及び配列構造のような所望の位相幾何を有することができ、このことは、広い範囲の適用にあうように可撓性を有することを意味する。

【0104】好ましい実施例において、FDN は 486 パーソナルコンピュータと四個のトランスピュータからなる回路網で遂行された。時間消費計算作業は、神経回路網訓練と診断、ファジィ論理ベースの仮説及び試験手順のような、トランスピュータ回路網で実施するように設計される。486-PC は、仕事指定、活動一致、ユーザーインターフェイス及びデータ獲得のためのホストコンピュータとして作用する。複数の機械、即ち部品は

このシステムを用いて監視することができる。以下に、好ましい実施例によって利用されたトランスピュータ回路網のハードウェアとソフトウェアの形状と、FDN診断及び訓練手順の実施とともに、トランスピュータ回路網上のファジィ論理ベースの仮説及び試験手順について述べる。トランスピュータにおけるこれらの手順の性能が推定されて486PCの性能と比較される。好ましい実施例で使用された平行式処理ハードウェアはマイクロウェイのクワダピュータボード(MicroWay's Quadputer board)である。このクワダピュータは、単一スロットのAT形状要素ボードであり、四個のT800-25トランスピュータの制御論理を含んでおり、各トランスピュータは、ボード上で全部で16メガバイトとなるように4メガバイトの外部メモリを備えている。各トランスピュータの速度は、25メガヘルツ(MHz)である。

【0105】ボード上の各トランスピュータノードは、他のトランスピュータによって直接アクセスできないそれ自身の位置メモリを有しており、トランスピュータ間の接続部を横切って、情報を活動的に送ったり受けたりすることによって、直接伝達しあうことが必要である。図11は、クワダピュータボード上において四コンピューターのトランスピュータ1010-1040の物理的な接続を示す。このトランスピュータ1010-1040のトランスピュータ回路網は、パイプライン及び木のよう異なる形状とすることが可能である。何故ならば、各トランスピュータは他の三個のトランスピュータと接続しているからである。例えば、木の形状において、“ルート”トランスピュータと呼ばれるトランスピュータ1010は、トランスピュータ2020、トランスピュータ3030、トランスピュータ4040にリンク1、2、3をそれぞれ介して接続される。図11からわかるように、四個の接続されていないリンクT1L0、T2L1T3L2、及びT4L3がある。これらリンクは、他のトランスピュータボードと接続したり、或いは、ホストコンピュータ(図示せず)と接続するために使用されるT1L0を除いて、同じボード上に二つのトランスピュータ間で複合接続するために用いることができる。これにより、ルートトランスピュータのロールはホストコンピュータと接続しデータI/O機能を行わなければならないので、ルートトランスピュータ1010のロールは非常に重要である。言い換えれば、ホストコンピュータ上に表示するために第一に、他のトランスピュータ内の全ての情報が、ルートトランスピュータ1010に伝えられなければならない。好ましい実施例において、33メガヘルツ(MHz)で走行する486PCは、ホストコンピュータとして使用される。もちろん、他のコンピュータも、当業者にとって明白なように使用することができる。

【0106】各情報の伝達は、ルートトランスピュータ

1010を通して行われなければならないので、回路網における伝達がより複雑になる。このため、プログラムは、どのノードがどのリンクを介して接続されているかというようなことを十分認識しなければならない。同時に回路網上で平行プログラムを遂行しなければならない。この問題を解決するために、表現(Express)1310と呼ばれる、伝達パッケージが、図14で示すように本明細書で用いられている。表現1310は、パラフォットセル社から入手可能である。特定のハードウェア、或いは形状が含まれているということに関係なく、このパッケージで、いかなるトランスピュータもメッセージを直接互いに送ったり受けたりすることができ、同様に、コンピュータ1050にもメッセージを送ったり、受けたりすることができる。図14は、表現1310を備えたハードウェア構造を表しており、表現1310を通して、ホストPC1105と全てのトランスピュータノードが互いに接続されている。表現1310によって提供された二つのプログラムモデルがある。一つは、キュービックス(Cubix)モデルであり、もう一つは“ホストノード”モデルである。キュービックスモデルは概念的に最も簡易なものである。このモデルにおいて、平行式プログラムはデータとファイルI/O、図形、ユーザーインターフェイス等を含んでおり、負荷された、トランスピュータノード上で遂行されなければならない。このアプローチの利点は、このプログラムは容易に誤りを探して訂正し、拡張し、維持することである。このアプローチの欠点は、トランスピュータノード上で手に入るメモリよりも多くのメモリを必要とすることである。

【0107】“ホストノード”モデルは、トランスピュータノード上の活動を調整し制御するホストコンピュータ上で走行するプログラムを書き取ることをしいられる。このモデルにおいて、全てのI/Oは、ホストプログラムによって処理されなければならない、メッセージをトランスピュータノードに送る。このアプローチの利点は、I/O速度がより速く、更に、より複雑な図形的なユーザーインターフェイスを提供できることである。これら二つの特性は、適応性において極めて重要である。更に、キュービックスモデルがホストコンピュータ上でそのままである場合には、キュービックスモデルの下でのトランスピュータ周囲に対して、展開された図形的ユーザーインターフェイスとデータ獲得コードを左側に配置することは無駄である。このため“ホストモード”モデルは、好ましい実施例において、プログラムモデルとして使用される。この好ましい実施例において、ホストPC1105に使用された、プログラム言語はターボ(Turbo)C++であり、トランスピュータノードの平行状プログラムが、論理システムCを用いて書き取られ、これに従う。上述したように、修正ARTMAP回路網200の診断は、回路網200に与えられる各パターン

に対して最もありうる二つの故障をみつけだすように設計されている。これら二つの可能性のある故障を捜し出すことは、486 PC上で連続してなされる。これは、修正ARTMAP回路網200が、第一の可能性のある故障として、警戒テスト250を通るF2層内の第一のノードを捜し出し、次いで、第二の故障の可能性として次のノードを見つけ出すことを意味する。好ましい実施例において、この手順はトランスピュータ上で行われる。図15は、FDN診断手順のトランスピュータの採用を表すということを示してきた。

【0108】単一のT800-25トランスピュータは、486 PCよりもかなり遅い。これは、T800-25トランスピュータのCPU速度が486 PCよりも遅いだけでなく、トランスピュータ手段内に含まれる全体的な伝達があるからである。しかしながら、トランスピュータの平行処理の利点は、一つのトランスピュータを用いる効率と、二つのトランスピュータを用いるときの効率とを比較するとき、重要になってくる。診断のこの効率は、約42パーセント(0.19秒から0.11秒)増大する。更に、5つのパターンを診断する際に、二つのトランスピュータを使用するときの性能、486 PCと同じである。更に、診断回数の分散は、複数のトランスピュータのために多い。トランスピュータは、第一回の試みでより時間がかかる傾向にある。これは、全ての回路網情報が第一回目に伝達され、入力ベクトルのみがこの後に伝達されなければならないからである。修正ARTMAP回路網200訓練手順(図5、6を参照)において最も時間のかかる作業は、ボトムアップ重み(B_{ij})とトップダウン重み(T_{ji})の適合である。これは、重みの適応は、各訓練パターン毎に任意的

に行われるからである。以下述べるように、FDN重み適合の手順はトランスピュータ回路網上でなされる。

【0109】修正ARTMAP回路網200の訓練手順のトランスピュータ手段が図12に示されている。手段の異なる方法が考慮された。即ち、1個、2個、3個のトランスピュータを使用して、警戒試験240と250を通り、重み適合手順を実施する、F2層内のノードを検索することである。第一の場合、全ての重み適応が連続的にトランスピュータ1110でなされる。第二の場合、F2層240と写像フィールド130との間の重みの更新が一個の1110上で遂行され、ボトムアップとトップダウン重み適合が、第二のトランスピュータ1120上でなされる。次いで、ボトムアップとトップダウン重みは、最後のケースにおいて、更に分割されて、二つのトランスピュータ1120と1130上で作動するようになる。上述したように、F2層230内の正規化された入力ベクトルPは、各重み更新が繰り返される毎に、更新される。このように、第二のトランスピュータ1120内において、ベクトルPの計算は、トップダウン重みが更新された後になされる。次いで、新しく更新

されたベクトルPは第三トランスピュータ1130に送られ、ボトムアップ重み適合(式(35)を参照)に使用される。このように、トランスピュータ1120からトランスピュータ1130への単一方向伝達リンク1140がある。

【0110】トランスピュータ上におけるこの手順のためのプログラム論理は診断の場合と同じである。目標出力ベクトル220と、F2層240と写像フィールド130との間の重みの双方がトランスピュータに送られなければならないという事だけが相違している。486 PCは他の三つのトランスピュータの手段の構造より、かなり早いということを示してきた。更に、一つのトランスピュータの使用から二つのトランスピュータを使用する訓練性能を向上させることは、さほど重要ではない(約5パーセント)。最も悪化した訓練性能は、三つのトランスピュータを使用するときを生じる。486 PCよりもほぼ3倍遅くなる。訓練時間が遅くなるのは、ノード1と2間に含まれた全体的に大きな伝達があるからである。訓練時間の偏差に関して、486 PCはより大きな偏差を有する。何故ならば複数の回路網リセット数が、後の訓練パターンに対して、より多くなる傾向にあり、このことは、訓練時間がより長くなる必要性があることを意味するからである。しかしながら、トランスピュータの偏差は、訓練内に含まれた全体的な伝達がないので486 PCほどは大きくない。このように、後者の試験は時間が長くかかる。

【0111】他の実施例は、ホストPCとトランスピュータの作業が平行になされることによって、複数のプロセッサを用いる。ホストPCが、第一訓練パターンに対してファイルとデータI/Oを終了するとき、ユーザーから次の訓練パターンのための情報を続けて受け取り、更に、トランスピュータはホストPCからデータを受け取って、訓練プロセスを開始する。五つの試験後のこのアプローチからの全I/Oと訓練時間の減少は、約12.6パーセント(45.02秒から39.35秒)である。以下に、ファジィ論理ベースの故障仮説検定手順のトランスピュータ手段について述べる。上述したように、この手順の目的は、故障診断回路網が認識できないパターンに対して、困難な故障推論を遂行することである。ファジィ論理ベースの故障仮説検定手順は、最初に、例えば与えられたベアリングパラメータ、機械走行状態、およびベースライン振動シグネチャに基づいた六個の基準パターンを発生し、次いで、これらの発生したパターンを与えられた未知の振動シグネチャと比較して、これらの間の類似性を判断する。図13は、一個のトランスピュータと三個のトランスピュータを使用する故障仮説検定手順のトランスピュータ手段を示す。一個のトランスピュータを使用する場合、六個のベアリングの欠陥の発生と比較は、連続して単一のトランスピュータ1110上でなされる。三個のトランスピ

ユータ 1 1 1 0—1 1 1 3 0 を使用する場合、各一個のトランスピュータが二つの欠陥パターン上で作動するように指定された状態で、全てのトランスピュータは平行に作動する。ホストトランスピュータ 1 1 0 5 は I/O とユーザーインターフェイスに反応可能であり、同様にベアリングパラメータ、機械走行状態等をトランスピュータノードに送り、全ての三個のトランスピュータ 1 1 1 0—1 1 1 3 0 から出力（即ち、同一）を受け取る。

【0 1 1 2】4 8 6 P C は、単一のトランスピュータよりも早い。しかしながら、作業が、三つのトランスピュータによってなされた三個に分離するとき、平均減少時間は約 3 7 パーセント（0. 6 0 秒から 0. 3 8 秒）である。より多くの欠陥がモデル内に含まれており、同時により多くのトランスピュータがこの手順を遂行するのに用いられる場合には、故障仮説検定手順の遂行を非常に向上できる。

6. 結論

今日、製造会社は、ますますメンテナンスプログラムにおいて予測メンテナンスを採用するようになっている。本明細書で述べた故障システムは、効率的な予測メンテナンスプログラムを提供する。強固なオンライン故障診断を実施する能力を備えて、システムは、機械のダウンタイムと費用をかなり削減することができる。本発明は、好ましい実施例について詳細に示し、述べてきたが、当業者は、本発明の精神と範囲から逸脱することなく形状において様々な変更が行えることがわかる。

付録 A

物理的ベアリンモデル

幾何は、ベアリング欠陥振動信号周波数 (Braun, S. Mechanical Signature Analysis: Theory and Application, Academic Press, London, 1986; Sandy, J., "Monitoring and Diagnostics for Rolling Element Bearings," Sound and Vibration, June 1988, pp. 16-20 を参照) を計算するための論理な式のリストである。

【0 1 1 3】

【数 1 7】

$$f_{ir} = \frac{N}{120} (n) \left(1 + \frac{d}{D} \cos \alpha \right) \quad (A.1)$$

$$f_{er} = \frac{N}{120} (n) \left(1 - \frac{d}{D} \cos \alpha \right) \quad (A.2)$$

$$f_c = \frac{N}{120} (n) \left(1 - \frac{d}{D} \cos \alpha \right) \quad (A.3)$$

$$f_{rs} = \frac{N}{120} \left(\frac{D}{d} \right) \left[1 - \left(\frac{d}{D} \cos \alpha \right)^2 \right] \quad (A.4)$$

$$f_m = \frac{N}{60} (n) \pm 2 \left(\frac{N}{60} \right) \quad \left\{ \begin{matrix} A: \hat{S} \\ B: \hat{S} \end{matrix} \right\}$$

$$f_{im} = \frac{N}{60}$$

【0 1 1 4】ここで、N は、軸速度 (CPM) である。n は、回転要素の数である。d は、回転要素の直径である。D は、ベアリングピッチの直径 (ローラの中央に対

する) である。α は、接触角である。f_{ir} は、内側レース欠陥である。f_{er} は、外側レース欠陥である。f_c は、ケージ欠陥である。f_{rs} は、ローラスピンである。f_m は、不整列である。f_{im} は、軸の不均衡である。

【図面の簡単な説明】

【図 1】予測適合推論理論 (ART)、又は ARTMAP と言われる神経回路網アーキテクチャである。

【図 2】監視学習を遂行するための修正 ARTMAP 回路網である。

【図 3】本発明の 3 段階を表すフレームワークである。

【図 4】診断システムを監視する、積分された機械の高レベルブロック線図である。

【図 5】修正 ARTMAP 回路網の訓練手順のフローチャートである。

【図 6】修正 ARTMAP 回路網の訓練手順のフローチャートである。

【図 7】回路網の診断手順である。

【図 8】本発明によって使用される故障診断の三レベルである。

【図 9】修正 ARTMAP 回路網の F₁ 層のより詳細な図である。

【図 10】本発明の好ましい実施例に従って採用されたファジィ論理ベースの仮説検定手順である。

【図 11】クワドピュータボード上の四個のトランスピュータの物理的接続である。

【図 12】故障診断回路網訓練手順のトランスピュータである。

【図 13】一個のトランスピュータと三個のトランスピュータを用いる仮説検定手順を採用するトランスピュータである。

【図 14】ソフトウェアパッケージ表現を含むトランスピュータベースのアプローチのアーキテクチャ線図である。

【図 15】故障診断手順を採用するトランスピュータである。

【図 16】本発明に従って設計された積分システムの故障診断手順のフローチャートである。

【図 17】本発明に従って設計された積分システムの故障診断手順のフローチャートである。

【図 18】例示的入力ベクトルを備えた ART 2 回路網である。

【図 19】新しいデータ作動するか、或いは自動相関推定するパラメトリックモデリングの概略図である。

【図 20】正常な機械状態を表す残余の予測した不規則な分布のプロットである。

【図 21】本発明に従って EWMA を計算するのに使用された方法論の詳細なフローチャートである。

【図 22】加速器、対周波数の感知反応 (振幅) の表示である。

【図 23】 指数関数的に重み付けされた移動平均を利用する診断及び監視手順のフローチャートである。


【図 24】 三つの異常状態を表す EWMA チャートである。

【符号】


130 写像フィールド
140 警戒パラメータ
200 ARTMAP 回路網

225 ART モジュール
400 診断システム
410 データ獲得モジュール
420 診断技術モジュール
430 機械モデル化モジュール
440 データベースモジュール
450 インターフェイス
460 システム制御モジュール


【図 1】



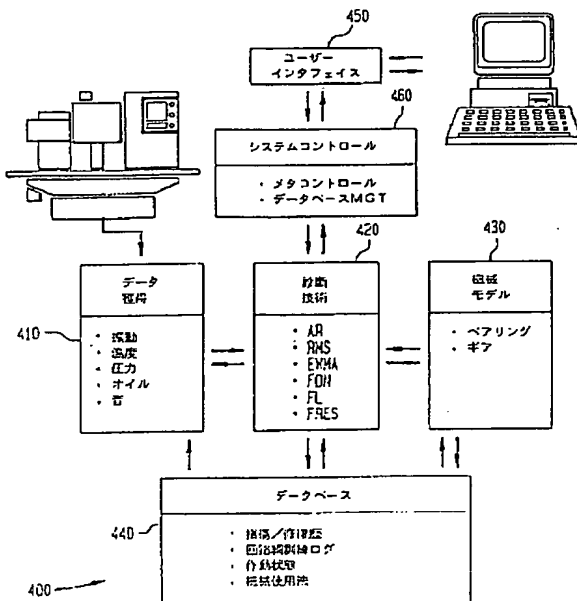
【図 2】




【図 3】




【図 4】




【図 8】




【図 19】




【図 5】




【図 9】




【図 10】




【図 14】




【図 22】




【図 6】



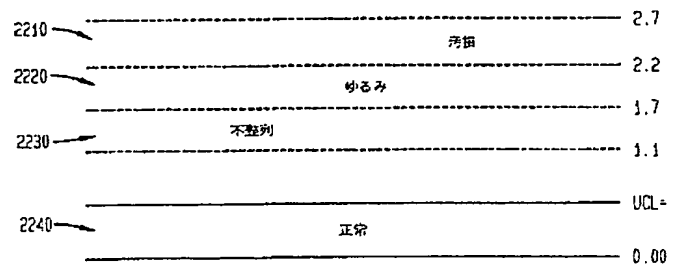
【図 1 8】




【図 1 1】




【図 2 4】




【図 7】



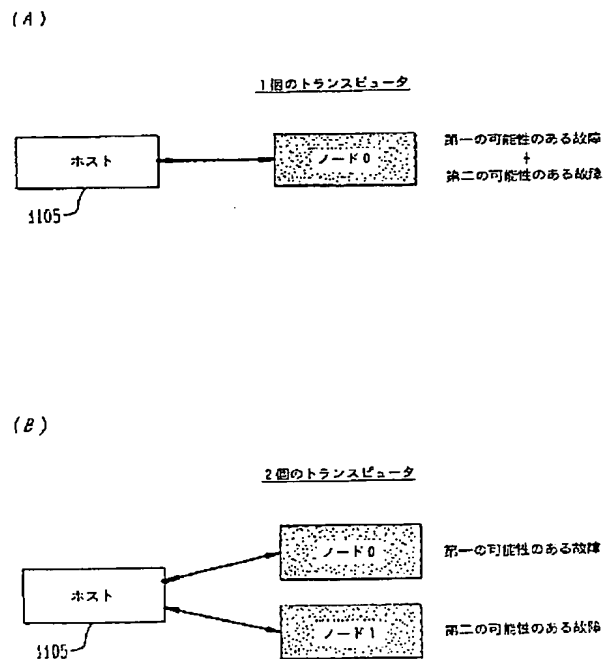
【図 20】



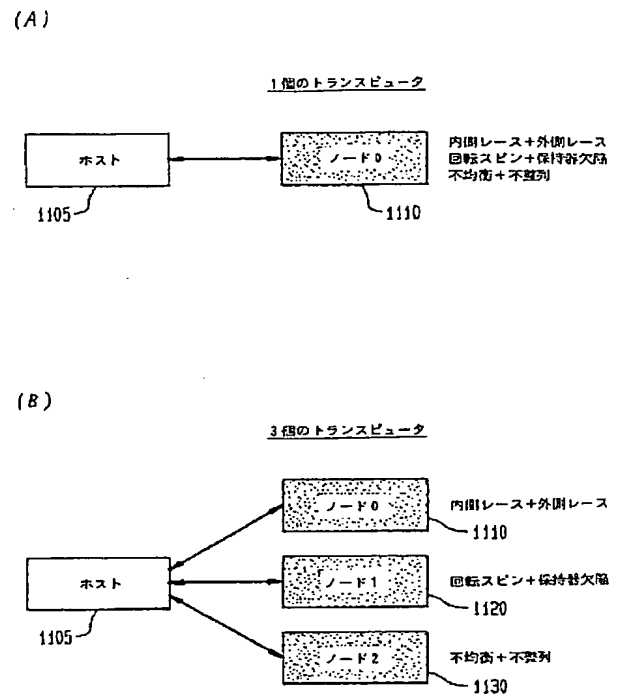
【図 12】




【図 15】



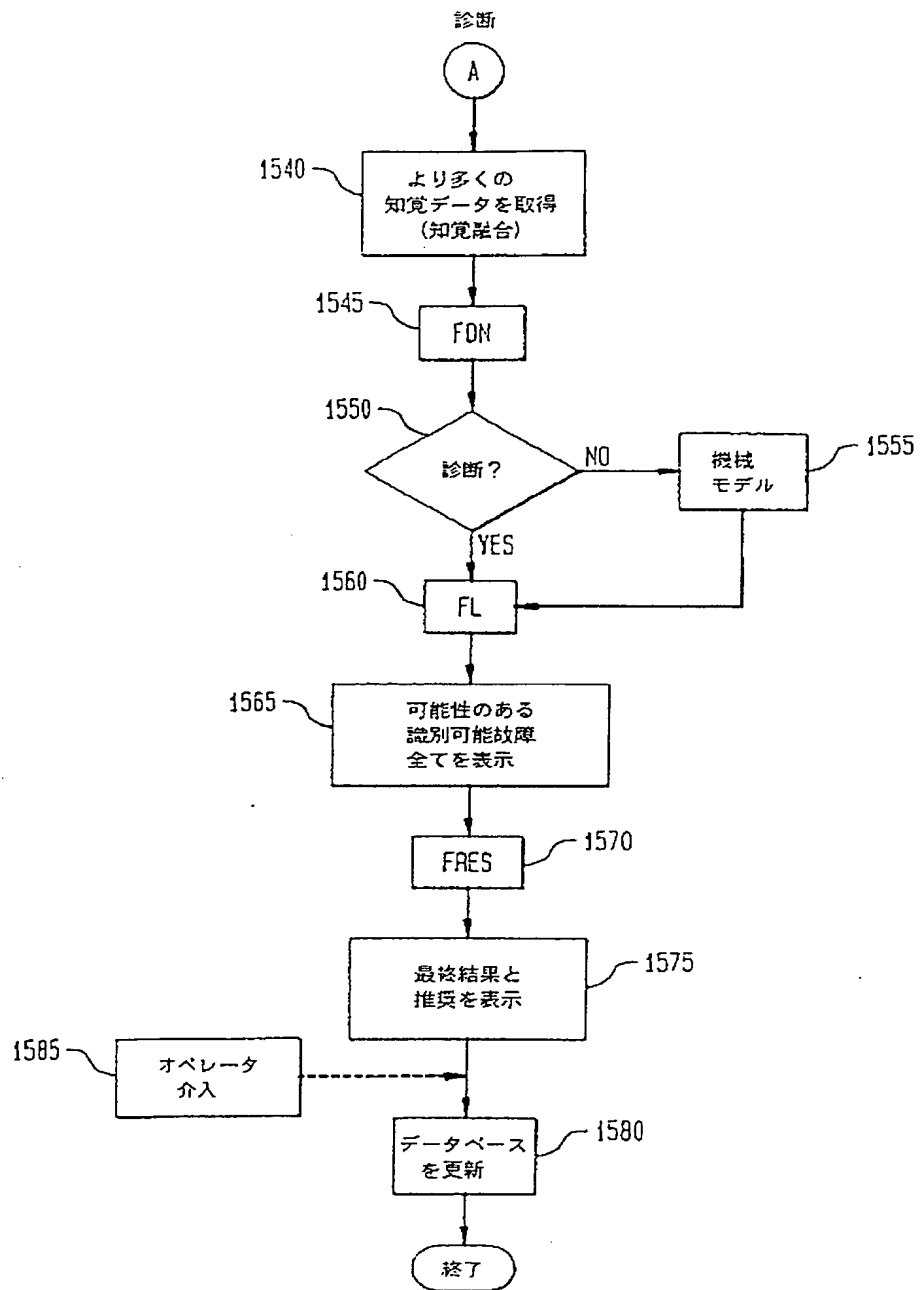
【図 13】



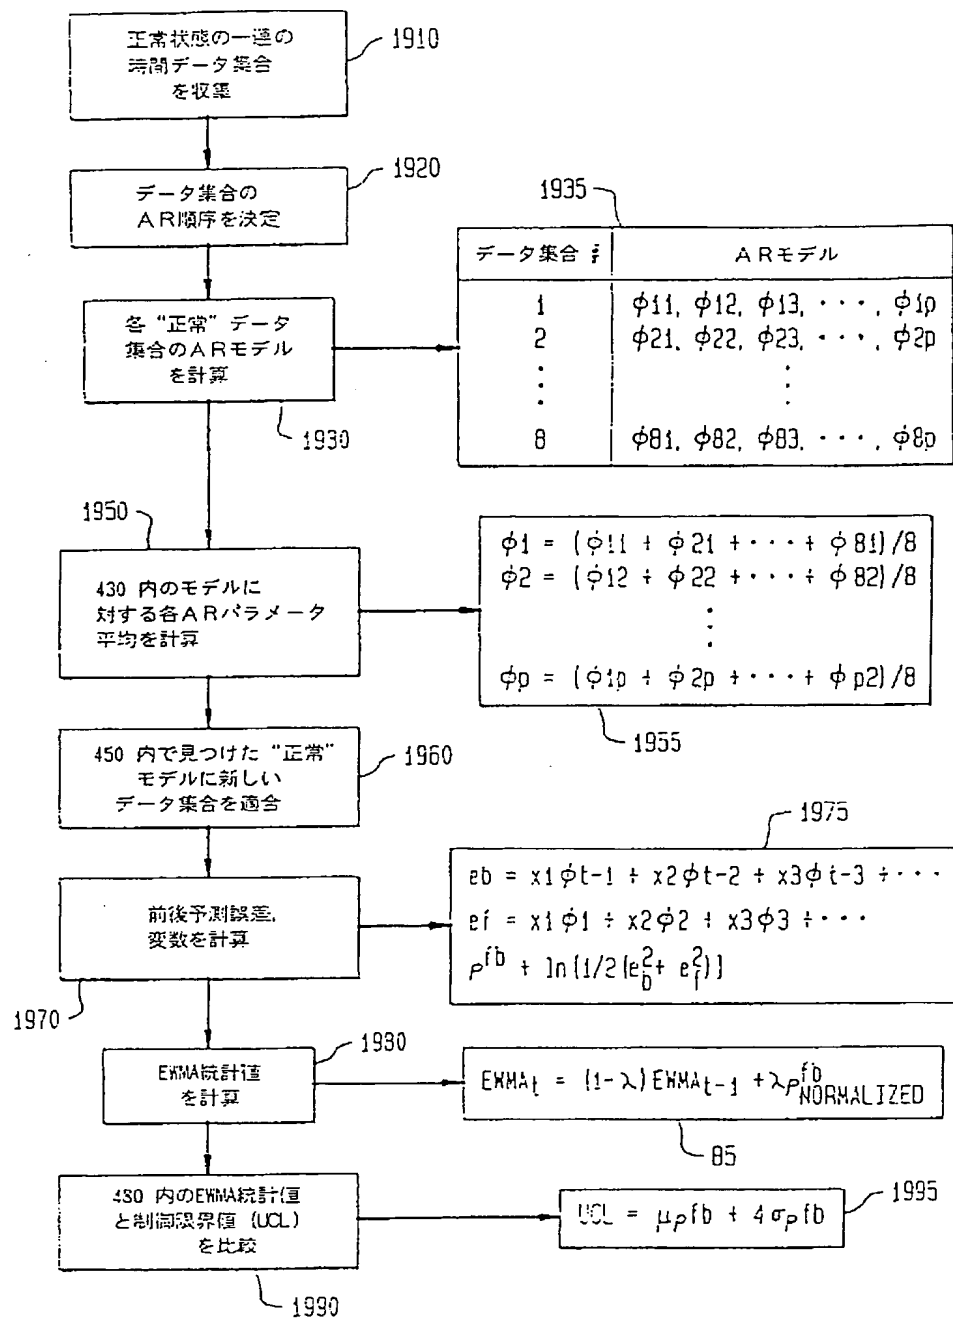
【図 16】



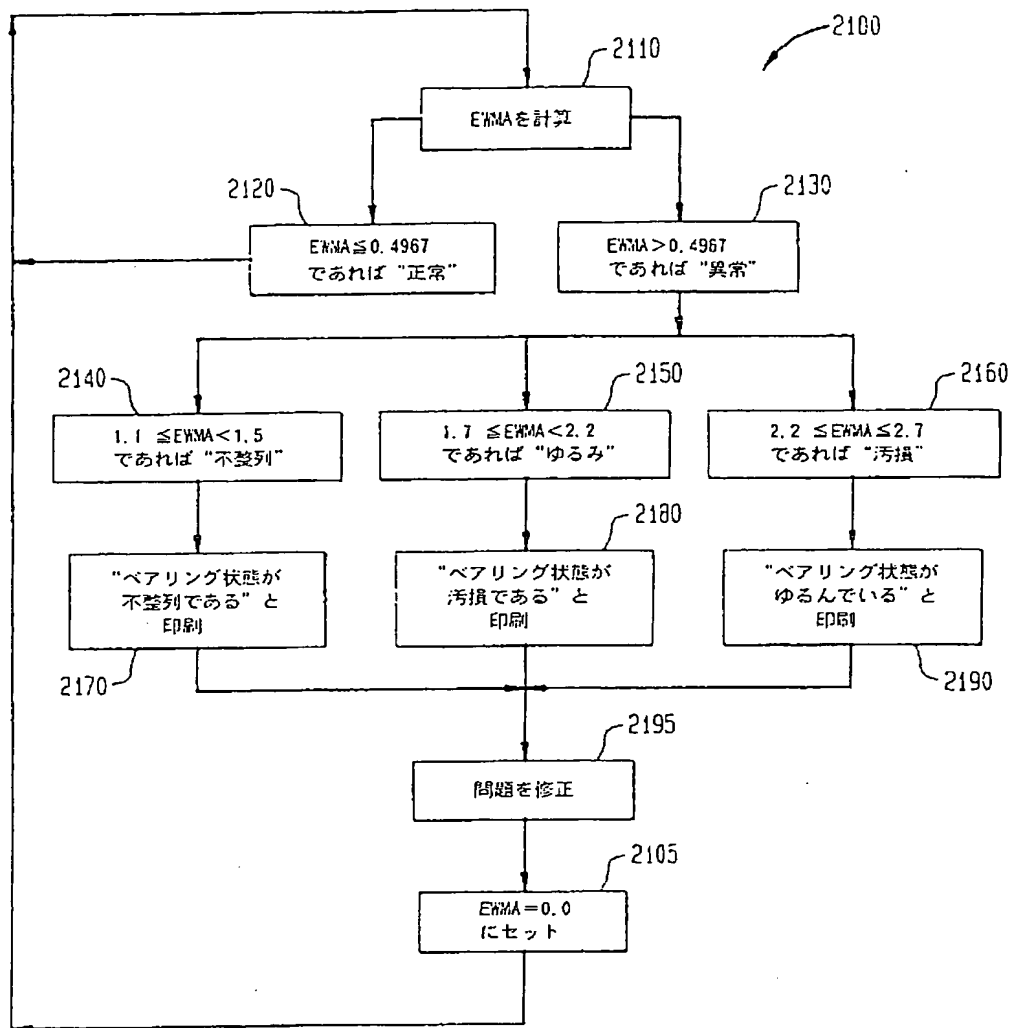
【図 1 7】



【図 21】



【図23】



フロントページの続き

(72) 発明者 シュイ シュン リン
 アメリカ合衆国 フロリダ州 32310 タ
 ラハッシー パネル サークル 1-334
 (72) 発明者 ジェラルド エム ナップ
 アメリカ合衆国 ルイジアナ州 70808
 バトン ルージュ グレンモア アベニュー
 1765

(72) 発明者 スー ピン ワン
 アメリカ合衆国 フロリダ州 32308 タ
 ラハッシー シャムロック ノース 3029
 (72) 発明者 チャン チン リン
 アメリカ合衆国 フロリダ州 32310 タ
 ラハッシー パネル サークル 7-313
 (72) 発明者 ジュリー ケイ スポール
 アメリカ合衆国 フロリダ州 32303 タ
 ラハッシー ドーフィン ブールヴァード
 4716